RENATO JOSÉ PINO DE ARAÚJO

OTIMIZAÇÃO DE DESEMPENHO DE INDICADORES DE CONTINUIDADE DO SERVIÇO EM CONCESSIONÁRIAS DE DISTRIBUIÇÃO UTILIZANDO ALGORITMOS EVOLUTIVOS

São Paulo
2011

RENATO JOSÉ PINO DE ARAÚJO

OTIMIZAÇÃO DE DESEMPENHO DE INDICADORES DE CONTINUIDADE DO SERVIÇO EM CONCESSIONÁRIAS DE DISTRIBUIÇÃO UTILIZANDO ALGORITMOS EVOLUTIVOS

Tese apresentada ao Departamento de Engenharia de Energia e Automação Elétricas da Escola Politécnica da Universidade de São Paulo para a obtenção do título de Doutor em Engenharia.

São Paulo
2011

RENATO JOSÉ PINO DE ARAÚJO

OTIMIZAÇÃO DE DESEMPENHO DE INDICADORES DE CONTINUIDADE DO SERVIÇO EM CONCESSIONÁRIAS DE DISTRIBUIÇÃO UTILIZANDO ALGORITMOS EVOLUTIVOS

Tese apresentada ao Departamento de Engenharia de Energia e Automação Elétricas da Escola Politécnica da Universidade de São Paulo para a obtenção do título de Doutor em Engenharia.

Área de Concentração :
Sistemas de Potência

Orientador: Dr. Nelson Kagan

São Paulo
2011

DEDICATÓRIA

A meus pais, Getúlio (*in memorium*) e Maria Cícera, a minha esposa Ritinha, e meus filhos Renatinha e Victor.

AGRADECIMENTOS

Desejo expressar meus sínceros agradecimentos:

Ao Professor Nelson Kagan pela orientação e paciência que tornou possível a finalização deste trabalho.

Aos Professores Marcos Gouvea, Carlos Tahan, Hérnan Prieto, e Carlos Barioni pelo apoio, estímulo durante a elaboração do trabalho.

À Xerxes Perreira gerente do projeto de pesquisa e José Antônio Brito de Sousa gestor dos projetos de pesquisa da COELBA, os quais tornaram possível a construção do trabalho base desta Tese.

A Professora Máriana pela enorme contribuição em quase todo trabalho.

A Professora Mônica Silveira pelas contribuições durante as revisões, na edição do textos, dos dados e gráficos utilizados.

A Robson Silva, impávido e infalível como Bruce Lee, que tornou possível a utilização dos softwares.

Aos amigos André Valente, Luciano Hocevar que de forma consistente e frequente me encorajaram e cobraram a finalização deste trabalho.

A todos (muitos) aqueles que compartilharam das angústias (muitas) e alegrias deste trabalho.

Sei lá, mil coisas...

(Pai Ubu na Peça de Teatro Ubu - Folias Physicas, Pataphysicas e Musicaes – Teatro do Ornitorrinco 1985 São Paulo)

RESUMO

A partir da reestruturação dos serviços públicos de energia elétrica, foi criada uma série de novas ferramentas regulatórias, simulando e/ou criando um ambiente competitivo, para que as empresas busquem continuamente a evolução de seus indicadores e custos. Com a edição da Resolução nº 024, de 27 de janeiro de 2000, a Agência Nacional de Energia Elétrica (ANEEL) atualizou a regulamentação dos aspectos relativos à continuidade do fornecimento de energia elétrica. As metas de continuidade são definidas através do *cluster* ao qual cada conjunto de consumidores está vinculado. Os conjuntos são agrupados pelas suas características físicas: área, km de rede primária, número de consumidores, potência de transformadores instalada e consumo médio do conjunto. Um dos pontos focais desta resolução é a possibilidade de uma concessionária agrupar unidades consumidoras, considerando as características técnicas específicas de seu sistema elétrico. Desta forma, o agente regulador permite que as concessionárias modifiquem seus conjuntos de consumidores, desde que fiquem evidenciadas vantagens técnicas, econômicas e sociais da nova proposta em relação ao critério vigente de agrupamento. Visando aperfeiçoar a utilização dos recursos, direcionando as ações para modicidade tarifária e considerando a capacidade de prover condições de atendimento homogêneo, este trabalho busca combinar os consumidores de uma concessionária em conjuntos que minimizem o risco de multa e a necessidade de investimentos nas redes. Este é um problema semelhante ao de redistribuição de eleitores nos distritos de votação nos EUA, conhecido como *Political Districting*. Para resolver o problema de explosão combinatória resultante das possíveis combinações de áreas e minimizar as multas, o modelo proposto neste trabalho utiliza técnicas de computação evolutiva. A metodologia é ilustrada alterando os 419 conjuntos iniciais de uma concessionária por meio de um algoritmo genético (AG) e um algoritmo imunológico (AI) que otimiza o resultado proposto, minimizando o risco de multas pelo não cumprimento das metas de continuidade.

Palavras-chave: 1 Distribuição de energia elétrica. 2 Computação evolutiva. 3 Otimização combinatória.

ABSTRACT

From the restructuring of the Public Electric Power Sector, new regulatory tools were devised to simulate and create a competitive environment for companies to continuously seek targets for their indicators and costs. With the issue of Resolution nº 024 of January 27, 2000, the National Agency of Electric Energy (ANEEL) updated the rules in dealing with electricity supply continuity. The goals related to the continuity of service are defined through the cluster in which each set of consumers is bound. Consumers are grouped by their physical characteristics: area, length (km) of primary network, the number of consumers, power transformers installed capacity and average consumption. ANEEL allows the utilities to modify their sets of consumers, whenever the technical advantages, economic and social implications of the new proposal in relation to the current criterion of grouping become evident. Considering the possibility of avoiding unnecessary investments in networks, burdening the distribution tariff, this paper attempts to combine the consumers of a utility in sets that minimize the risk of penalties and network investments. This problem is similar to the redistribution in voting districts in the U.S., known as Political Districting. In order to solve the combinatorial explosion problem resulting from the possible combinations of areas and minimization of penalties, the model proposed in this paper uses evolutionary computation techniques. The case study alters the initial 419 sets of consumers of a utility through a genetic algorithm and an artificial immune algorithm, which were proposed to optimize the outcome, minimizing the risk of penalties in not meeting the goals related to continuity of service.

Keywords: 1 Distribuição de energia elétrica. 2 Evolutionary computation. 3 Combinatorial optimization.

LISTA DE ILUSTRAÇÕES

Figura 01	Metodologia de formação dos conjuntos e suas metas de continuidade	41
Figura 02	Modelo genérico de algoritmo genético	55
Figura 03	Exemplo no sistema slétrico de minimização das perdas com duas fontes	57
Figura 04	Representação binária de indivíduos numéricos	57
Figura 05	Modelagem de indivíduos com estrutura de dados	58
Figura 06	Indivíduos de uma população e a sua correspondente roleta de seleção	62
Figura 07	Operador Genético – Torneio	63
Figura 08	Exemplo de crossover de um ponto	64
Figura 09	Operador genético - Mutação	64
Figura 10	Diagrama de bloco do algoritmo de Seleção Clonal	71
Figura 11	Regiões de complementaridade para o reconhecimento antígeno-anticorpo	72
Figura 12	Possibilidades de agrupamento de 03 áreas	78
Figura 13	Divisão conjuntos nos agrupamentos/clusters	81
Figura 14	Novo conjunto de consumidores das áreas B e C e suas novas metas	84
Figura 15	Combinação de dois municípios – Área urbana e rural	86
Figura 16	Formação de um único conjunto	86
Figura 17	Formação de quatro conjuntos	86
Figura 18	Formação de conjuntos com áreas agrupadas três a três	86
Figura 19	Formação de conjuntos com áreas agrupadas dois a dois	87
Figura 20	Formação de conjuntos com áreas agrupadas dois, um,um	87
Figura 21	Matriz de restrição	88
Figura 22	Modelagem inicial do individuo	91
Figura 23	Regional fictícia e dados	92
Figura 24	Indivíduo atual	92
Figura 25	Indivíduo formado pela união das áreas (a+b), (c+d),(e+h),(f),(g).	92
Figura 26	Indivíduo formado pela união das áreas (a+f),(b),(c), (d+e+g),(h).	92
Figura 27	Indivíduo formado pela união das áreas (a), (b+d+g),(c+f),(e+h)	93
Figura 28	Indivíduo formado pela união das áreas (a+b), (c+d),(e+h),(f),(g)	93

Figura 29 Exemplo de Regional fictícia 99
Figura 30 Modelo do novo indivíduo 100
Figura 31 Indivíduo (a + b) (c + g), (d + e), (h), (f) (g) 100
Figura 32 Tela Principal do SOA 104
Figura 33 Parâmetros de entrada dos Algoritmos Genéticos 105
Figura 34 Exemplo de conjuntos fictícios 106
Figura 35 Modelo do novo indivíduo 106
Figura 36 Exemplo de indivíduo do novo modelo 106
Figura 37 Outro exemplo de indivíduo do novo modelo 107
Figura 38 Parâmetros do algoritmo de Seleção Clonal 113
Figura 39 Desempenho do indicador DEC (Brasil) – 2001 à 2008 118
Figura 40 Redistribuição de blocos de carga entre subestações 123
Figura 41 Modelagem das configurações do sistema de distribuição 124
Figura 42 Custos totais associados à confiabilidade 125

LISTA DE GRÁFICOS

Gráfico 01	Definição do limite de DEC para um conjunto de um cluster	43
Gráfico 02	Crescimento do tempo de processamento a partir do número de itens de entrada	52
Gráfico 03	Crescimento de partições – Número de Bell	52
Gráfico 04	Linearização da função avaliação	60
Gráfico 05	Função avaliação através do Ranking	61
Gráfico 06	Adaptabilidade por geração	65
Gráfico 07	Desempenho do AG na simulação do tipo 1	110
Gráfico 08	Resultados das simulações finais do AG	112
Gráfico 09	Simulação final do ASC com taxa de mutação de 20%	116
Gráfico 10	Simulação final do ASC com taxa de mutação de 50%	116
Gráfico 11	Comparação entre o Algoritmo Genético e o Agoritmo de Seleção Clonal	117
Gráfico 12	Simulações com algoritmos genéticos tipo 1	138
Gráfico 13	Simulações com algoritmos genéticos tipo 2	138
Gráfico 14	Simulações com algoritmos genéticos tipo 3	138
Gráfico 15	Simulações com algoritmos genéticos tipo 4	139
Gráfico 16	Simulações com algoritmos genéticos tipo 5	139
Gráfico 17	Simulações com algoritmos genéticos tipo 6	139
Gráfico 18	Simulações com algoritmos genéticos tipo 7	140
Gráfico 19	Simulações com algoritmos genéticos tipo 8	140
Gráfico 20	Simulações com algoritmos genéticos tipo 9	140
Gráfico 21	Simulações com algoritmos genéticos tipo 10	141
Gráfico 22	Simulações com algoritmos genéticos tipo 11	141
Gráfico 23	Simulações com algoritmos genéticos tipo 12	141
Gráfico 24	Simulações com algoritmos genéticos tipo 13	142
Gráfico 25	Simulações com algoritmos genéticos tipo 14	142
Gráfico 26	Simulações com algoritmos genéticos tipo 15	142
Gráfico 27	Simulações com algoritmos genéticos tipo 16	143
Gráfico 28	Simulações com algoritmos genéticos tipo 17	143
Gráfico 29	Simulações com algoritmos genéticos tipo 18	143

Gráfico 30 Simulações com algoritmos genéticos tipo 19 144
Gráfico 31 Simulações com algoritmos genéticos tipo 20 144
Gráfico 32 Simulações com algoritmo de seleção clonal Tipo 1 154
Gráfico 33 Simulações com algoritmo de seleção clonal Tipo 2 154

LISTA DE TABELAS

Tabela 01	Resumo da reestruturação o setor elétrico	19
Tabela 02	Valores máximos anuais de DEC da Portaria no 046/78/ DNAEE	34
Tabela 03	Atributos dos diversos conjuntos	42
Tabela 04	Dados para o estudo de rezoneamento escolar de Middletown	48
Tabela 05	Representação binária de um indivíduo	56
Tabela 06	Padrões de continuidade Individuais	82
Tabela 07	Dados de conjuntos da COELBA	89
Tabela 08	Dados de conjuntos combinados - 1	89
Tabela 09	Dados de conjuntos combinados - 2	90
Tabela 10	Valores dos parâmetros inicialmente analisados para o AG	105
Tabela 11	Parâmetros mantidos constantes para todas simulações do AG	109
Tabela 12	Valores dos parâmetros analisados do AG	110
Tabela 13	Parâmetros mantidos constantes para novas simulações do AG	111
Tabela 14	Valores dos parâmetros utilizados nas simulações finais do AG	111
Tabela 15	Valores dos parâmetros analisados para o ASC	114
Tabela 16	Valores dos parâmetros analisados para o ASC	115
Tabela 17	Simulações com algoritmos genéticos tipo 1	145
Tabela 18	Simulações com algoritmos genéticos tipo 2	145
Tabela 19	Simulações com algoritmos genéticos tipo 3	145
Tabela 20	Simulações com algoritmos genéticos tipo 4	146
Tabela 21	Simulações com algoritmos genéticos tipo 5	146
Tabela 22	Simulações com algoritmos genéticos tipo 6	146
Tabela 23	Simulações com algoritmos genéticos tipo 7	147
Tabela 24	Simulações com algoritmos genéticos tipo 8	147
Tabela 25	Simulações com algoritmos genéticos tipo 9	147
Tabela 26	Simulações com algoritmos genéticos tipo 10	148
Tabela 27	Simulações com algoritmos genéticos tipo 11	148
Tabela 28	Simulações com algoritmos genéticos tipo 12	148
Tabela 29	Simulações com algoritmos genéticos tipo 13	149
Tabela 30	Simulações com algoritmos genéticos tipo 14	149

Tabela 31 Simulações com algoritmos genéticos tipo 15 149
Tabela 32 Simulações com algoritmos genéticos tipo 16 150
Tabela 33 Simulações com algoritmos genéticos tipo 17 150
Tabela 34 Simulações com algoritmos genéticos tipo 18 150
Tabela 35 Simulações com algoritmos genéticos tipo 19 151
Tabela 36 Simulações com algoritmos genéticos tipo 20 151
Tabela 37 Simulações com de seleção clonal Tipo 1 153
Tabela 38 Simulações com de seleção clonal Tipo 2 153

LISTA DE ABREVIATURAS E SIGLAS

ANEEL	Agência Nacional de Energia Elétrica
AG	Algoritmo Genético
AI	Algoritmo Imunológico
ASC	Algoritmo de Seleção Clonal
CODI	Comitê de distribuição
COELBA	Companhia de Eletricidade do Estado da Bahia
CUC	Conjuntos de unidades consumidoras
CGS	Custo Global do Serviço
DEC	Duração Equivalente de Interrupção por Consumidor
DIC	Duração de Interrupção por Consumidor
DMIC	Duração Máxima de Interrupção Contínua por Unidade Consumidora
DNAEE	Departamento Nacional de Águas e Energia Elétrica
ELETROBRÁS	Centrais Elétricas Brasileiras S.A
FEC	Frequência Equivalente de Interrupção por Consumidor
FIC	Freqüência de Interrupção por Consumidor
ICD	Interrupções de curta duração
ILD	Interrupções de longa duração
ISO	International Organization for Standardization
MOP	otimização multiobjetivo
NP	Não Polinomial
PL	Programação Linear
PI	Programação Inteira
PRODIST	Procedimentos de Distribuição
SOA	Sistema de Otimização da Multa Global de Continuidade
TAC	Termo de Ajuste de Conduta
TQC	Total Quality Control

SUMÁRIO

1 INTRODUÇÃO 18

1.1 CONTEXTUALIZAÇÂO 18

1.2 OBJETIVOS 22

1.3 METODOLOGIA 23

1.4 ESTRUTURA DA TESE 24

2 QUALIDADE NO FORNECIMENTO DE ENERGIA ELÉTRICA – CONTINUIDADE DO SERVIÇO 26

2.1 INDICADORES DE QUALIDADE 27

2.2 A IMPORTÂNCIA DA CONTINUIDADE NO FORNECIMENTO DE ENERGIA ELÉTRICA 30

2.3 A PORTARIA Nº 046/78/ DNAEE 32

2.4 LIMITAÇÕES DA PORTARIA DNAEE Nº 046/78 34

2.5 RESOLUÇÃO NORMATIVA ANEEL 024/2002 37

2.5.1 Critério de formação dos conjuntos 39

2.5.2 Metodologia de controle do desempenho de continuidade 40

2.5.3 A formação das metas coletivas dos conjuntos 43

2.5.4 Penalidades previstas 45

2.6 CONCLUSÕES DO CAPÍTULO 46

3 ALGORITMOS DE OTIMIZAÇÃO 47

3.1 O PROBLEMA DE OTIMIZAÇÃO 47

3.2 COMPLEXIDADE DE UM ALGORITMO 50

3.3 ALGORITMO GENÉTICO 54

3.3.1 O indivíduo/solução 56

3.3.2 População inicial 58

3.3.3 A função avaliação 59

3.3.4 Operadores genéticos 61

3.3.5 Critério de convergência 65

3.4 ALGORITMO IMUNOLÓGICO 66

3.4.1 Algoritmo de seleção clonal 70

3.4.2 Avidade e afinidade 72

3.4.3 Mecanismos de seleção 73

3.4.4 Proliferação e hipermutação somática 73
3.4.5 Diversificação 74
3.4.6 Critério de parada 75
3.5 CONCLUSÕES 75
4 METODOLOGIA PARA REDEFINIÇÃO DE CONJUNTOS DE CONSUMIDORES 77
4.1 REDISTRITING 77
4.2 REGRAS PARA DEFINIÇÃO DOS CONJUNTOS DE CONSUMIDORES E METAS DE CONTINUIDADE 80
4.3 METODOLOGIA PROPOSTA 82
4.4 OTIMIZAÇÃO PARA AGRUPAMENTO 85
4.4.1 A escolha do método de otimização 88
4.4.2 Modelagem do problema por AG 90
4.4.2.1 Codificação do indivíduo 91
4.4.2.2 População inicial 93
4.4.2.3 Função de avaliação 94
4.4.2.4 Métodos de seleção 95
4.4.2.5 Cruzamento, mutação e critério de parada 96
4.4.2.6 Problemas encontrados 97
4.4.3 Algoritmos imunológicos modificados 98
4.6 NOVA MODELAGEM PARA O PROBLEMA 100
4.7 ALGORITMOS IMUNOLÓGICOS 101
4.8 CONCLUSÃO DO CAPÍTULO 102
5 APLICAÇÃO DA METODOLOGIA 103
5.1 REDISTRIBUIÇÃO DOS CONJUNTOS DE CONSUMIDORES EM NOVOS CLUSTERS ATRAVÉS DE ALGORITMOS GENÉTICOS. 104
5.1.1 Análise inicial dos parâmetros 106
5.1.2 Melhor combinação entre os parâmetros 109
5.2 REDISTRIBUIÇÃO DOS CONJUNTOS DE CONSUMIDORES EM NOVOS CLUSTERS ATRAVÉS DO ALGORITMOS DE SELEÇÃO CLONAL 113
5.4 CONCLUSÃO DO CAPÍTULO 116
6 EXTENSÃO DA METODOLOGIA PARA CONJUNTOS GEOELÉTRICOS 118
6.1 ANÁLISE DA METODOLOGIA PROPOSTA PELA ANEEL 120

6.1.1 Quanto ao critério para formação dos conjuntos 120
6.1.2 Quanto à análise dos atributos 122
6.2 NOVO TRATAMENTO A CONTINUIDADE DE FORNECIMENTO 122
6.3 CONCLUSÕES DO CAPÍTULO 125
7 CONCLUSÕES DO TRABALHO 127
7.1 ASPECTOS GERAIS 127
7.2 LIMITAÇÕES DA METODOLOGIA 128
7.3 CONTRIBUIÇÕES 129
7.4 SUGESTÕES PARA FUTUROS ESTUDOS 131
REFERÊNCIAS 133
ANEXO I 138
ANEXO II 154

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÂO

Nas últimas décadas do século passado ocorreram diversas mudanças no cenário econômico mundial. A ascensão de um novo paradigma de produção[1] associado ao neoliberalismo ditou a reorientação de desenvolvimento econômico comandado pelo setor privado.

No setor de infra-estrutura, não existia mais o consenso de que os serviços públicos baseados em monopólios naturais estatizados e verticalizados constituíam uma forma superior de provisão, por associar baixos custos de produção devido à presença de economias de escala e escopo (PASSANEZI FILHO, 1998)[2.] Neste período, ocorreram as privatizações dos setores de infra-estrutura, com a transferência de portos, siderúrgicas, ferrovias, rodovias, telecomunicações e energia elétrica, para iniciativa privada em todo mundo (ROSA et al., 1998).

Neste novo contexto, em que o Estado deixa de atuar diretamente passando a regular o mercado, há a necessidade da criação de novos aparatos regulatórios para garantir o desempenho das infra-estruturas desestatizadas. Assim, foram desenvolvidos novos modelos de regulação que prevêem a privatização dos setores de infra-estrutura e a sua desverticalização, introduzindo a competição quando possível e criando novos instrumentos para aqueles nos quais as características de monopólio natural sejam ainda marcantes (PIRES e PICCININI, 1998).

No setor elétrico, as reformas que se generalizaram, tiveram como referência o processo de reestruturação do Reino Unido, que influenciou as reformas nos

---

1 Em função do desenvolvimento da microeletrônica, a automação rígida ou Taylorismo-Fordismo, paradigma dominante, foi tecnicamente superada pela automação flexível ou Toyotismo. (ALBAN, 2000).

2 Ao longo dos anos, diversas ineficiências foram observadas no funcionamento dos monopólios naturais. Desde então, a partir dos anos 60, começam a ser difundidas idéias e práticas a respeito da desregulação. Além disso, algumas inovações tecnológicas ajudaram os argumentos a favor da desregulamentação (FREITAS, 2000).

serviços de utilidade pública em todo mundo. (PIRES e PICCININI, 1998). Algumas modificações na indústria da eletricidade foram necessárias para adaptação a uma estrutura competitiva. Entre as principais mudanças que ocorreram, uma foi o tratamento diferenciado a cada uma de suas cadeias produtivas, geração, transmissão, distribuição e comercialização. A tabela 01, resume as reformas, que ocorreram na grande maioria dessas indústrias:

Tabela 01- Resumo da Reestruturação o setor Elétrico

Segmento	Regulação	Agentes
Geração	Competição	Capital Privado
Transmissão	Monopólio Natural	Operador Independente do Sistema - ISO
Distribuição	Monopólio Natural	Concessionárias
Comercialização	Competição	Comercializadoras

Fonte: **(**ROSA et al.,1998)

Na distribuição de energia elétrica, alvo deste trabalho, a existência das características de monopólio é bastante clara, sendo ainda considerado monopólio natural, portanto, sujeita a uma forte regulamentação.

Neste setor, a forma encontrada para melhorar o desempenho econômico foi criar a competição, com a permissão do livre acesso de um conjunto de consumidores à rede, e o conseqüente pagamento de pedágio pelo seu uso, de forma a remunerar os investimentos das concessionárias[3], além de introduzir a tarifação pelo Price-cap no lugar do tradicional método tarifário da taxa de retorno[4].

Na tarifação por Price-cap[5] é proposta uma tarifa teto que deverá ser aplicada por um determinado período, intervalos regulatórios, e ao seu final as tarifas serão reajustadas, pelos ganhos de produtividade alcançados pelas concessionárias e atualizadas por um índice de preços, que permita uma incorporação das mudanças nos custos e dos saltos tecnológicos (PIRES, 1999).

3 Esta medida permite a efetiva competição no setor. Os comercializadores compram energia através de contratos bilaterais com produtores de eletricidade ou no mercado *spot*, pagam a tarifa de transporte e vendem energia à grandes consumidores, sendo que em um futuro próximo todos os consumidores poderão usufruir desta opção.

4 Diversas críticas são feitas ao método tarifário da taxa de retorno. A principal é o não favorecimento das eficiências alocativa e produtiva, principalmente pela tendência ao sobreinvestimento. A introdução de uma nova abordagem para a questão levou à consagração do *Price-cap* como o principal instrumento de incentivo atualmente utilizado.

5 Evidentemente, este método tarifário deve ser usado para os consumidores cativos da distribuidora, já que os consumidores livres negociam bilateralmente o “preço”.

Entre as principais vantagens deste método estariam: menor custo da ação regulatória; maior simplicidade; menor risco de captura das agências[6]; incentivos à eficiência econômica pelas concessionárias (PIRES, 1999).

Entre as desvantagens deste método pode-se citar que estudos teóricos e empíricos sobre o desempenho de práticas regulatórias concluem que o *Price-cap* favorece ao subinvestimento e, conseqüentemente, a redução da qualidade pelas concessionárias, daí a necessidade de novos mecanismos para obrigar as concessionárias a investir para manter os níveis de qualidade do serviço e do produto. (PIRES e PICCININI, 1998)

A qualidade no fornecimento de energia elétrica envolve um *trade off* frente à necessidade de investimentos. A princípio, a necessidade de tarifas baixas contrapõe-se à questão da qualidade, já que está diretamente correlacionada ao nível de investimentos. No caso do modelo de tarifação pelo *Price-cap*, a questão parece ser ainda mais complexa, devido à incessante busca por redução de custos[7].

Neste contexto, existiu a necessidade de introduzir novos mecanismos para obrigar as concessionárias a oferecer uma qualidade mínima no fornecimento de energia elétrica. A edição das resoluções normativas 024/ANEEL/2000, que estabelece as disposições relativas à continuidade da distribuição de energia elétrica às unidades consumidoras, e 505/ANEEL/2000, que cria de forma atualizada e consolidada as

---

6 A adoção do *Price-cap* contribuiria para reduzir o risco de captura das agências reguladoras (ao não expô-las a uma situação de assimetria de informações) e para incentivar a ação eficiente das firmas, uma vez que, com preços fixos, estas poderiam apropriar-se da redução de custos que viesse a ocorrer entre os períodos revisionais. Contudo, este método de tarifação requer a definição, pelo regulador, de uma série de variáveis relevantes, tais como: indexador de preços e fator de produtividade, grau de liberdade para a variação de preços relativos, grau de extensão dos repasses dos custos permitidos para os consumidores e formas de incentivo ao investimento e à qualidade do atendimento (PIRES, 1999).

7 Um dos problemas mais difíceis dentro do sistema de prestação de serviços de energia elétrica sob o regime de concessão refere-se à garantia da qualidade do serviço. Os contornos da questão são claros: cabe ao Estado, através do agente regulador, estabelecer o preço permissível e definir os padrões de prestação dos serviços, controlando o desempenho da empresa concessionária dentro desses padrões. Apesar da aparência simples, a prática desta incumbência apresenta grande complexidade, à medida que exige a contínua reavaliação de um equilíbrio entre interesses que são, em certa medida, conflitantes. Espera-se que o órgão regulador estabeleça, por um lado, um preço que propicie retorno atraente e induza investimentos, num ambiente de negócios em permanente transformação e sujeito a consideráveis oscilações conjunturais. Uma vez estabelecido o preço, a empresa concessionária fará todos os esforços para reduzir custos e obter a maior remuneração possível sobre o investimento. [...] É na contradição dos interesses envolvidos e na natureza mutável das condições de concessionário e usuários que reside a dificuldade em garantir o nível adequado de qualidade na prestação de serviços. (GHIRARDI, 2000).

disposições relativas à conformidade dos níveis de tensão de energia elétrica em regime permanente, é o resultado deste viés regulatório.

Segundo TANURE (2000), embora já existisse o estabelecimento de padrões para a qualidade mínima de fornecimento através das Portarias DNAEE 046/78 e 047/78, até 1999, a maior parte das concessionárias brasileiras ainda não possuía uma política de monitoramento da qualidade de fornecimento de energia elétrica, pois, além da inexistência do processo de fiscalização, não se estabeleceu nenhum tipo de punição pelo não cumprimento dos padrões propostos.

Outro aspecto importante citado pelo mesmo autor é referente à impossibilidade de estabelecer comparação entre o desempenho das diversas concessionárias[8]:

> Os contratos de concessão assinados até 1999 apresentam várias formas de tratamento para o estabelecimento de metas para estes conjuntos. Sendo que, em sua maioria, os padrões de desempenho futuros para as empresas foram definidos considerando valores médios calculados com base nos desempenhos verificados nos anos anteriores. Este tipo de abordagem permite estabelecer metas de melhoria de desempenho para cada conjunto, porém não permite estabelecer uma comparação entre os conjuntos de uma mesma empresa, tampouco comparar o desempenho de conjuntos das diferentes empresas.

A partir da Resolução ANEEL 024/2000, iniciou-se um novo processo de regulação e fiscalização da qualidade da energia. Na abordagem proposta, as concessionárias deveriam estabelecer conjuntos de consumidores dentro de sua área de concessão considerando sua capacidade de prover condições de atendimento homogêneas por área.

Para o tratamento estatístico dos conjuntos formados pelas empresas, adotou-se o método de Análise de Agrupamentos[9], que permite agrupar conjuntos com

---

8 *Yardstick Competition* ou desempenho por comparação possui por trás a lógica, que o comportamento de partes do sistema que suprem áreas homogêneas, em diversas concessionárias, devem ser próximos, tanto em relação aos custos quanto ao desempenho. A regulação por comparação foi uma das novas ferramentas introduzidas nas recentes reestruturações dos serviços públicos e é uma forma de reduzir as assimetrias de informação existentes e estimular maior eficiência econômica.

9 A análise de agrupamentos (*Clusters Analisys*) é uma técnica analítica para desenvolver subgrupos significativos de indivíduos ou objetos. Especificamente, o objetivo é classificar uma amostra de entidades (indivíduos ou objetos) em um pequeno número de grupos mutuamente excludentes, com base nas similaridades entre as entidades (HAIR ET al., 2005).

características semelhantes, de acordo com atributos previamente definidos. Os atributos eleitos pela ANEEL, principalmente pela facilidade de aquisição, foram:

1. Área de cada conjunto, em km^2;
2. Extensão da rede primária, em km;
3. Potência Instalada, em kVA;
4. Número de consumidores;
5. Consumo médio mensal, em MWh.

A metodologia foi inicialmente aplicada a 4.135 conjuntos de 56 concessionárias (TANURE, 2000), em cerca de trinta agrupamentos, com metas individuais e coletivas para os consumidores.

Evidentemente, era esperado que os conjuntos de consumidores fossem compostos por áreas homogêneas. Assim, grandes centros urbanos brasileiros estariam agrupados em um *cluster* e cidades históricas e turísticas como: Porto Seguro, Parati, ou Angra dos Reis estariam em outro agrupamento. A correta determinação destes atributos seria uma das etapas mais sensíveis da metodologia.

Nos primeiros ciclos de sua aplicação, a formação de conjuntos e metas foi negociada com as concessionárias, já que as orientações da ANEEL eram apenas: a não existência de número mínimo de consumidores por conjunto; a orientação para um número máximo de cinqüenta mil consumidores; o conjunto não ter vínculo com sistema elétrico e apresentar características homogêneas.

1.2 OBJETIVOS

A relativa flexibilidade existente para formação dos conjuntos permite que as concessionárias estabeleçam estes de maneira a minimizar o risco de punição por ultrapassagem das metas de continuidade estabelecidas pela ANEEL (STRAUCH; et al., 2005). Este viés regulatório permite às concessionárias reduzir custos e priorizar seus investimentos de forma a conduzir a uma modicidade tarifária, em consonância com o atual contexto no qual estão inseridas as concessionárias de distribuição.

Por outro lado, as metas dos conjuntos são decrescentes e reavaliadas/reduzidas a cada revisão tarifária, o que levará a uma convergência destas metas dos conjuntos nos próximos ciclos de revisões[10], sinalizando para uma melhor qualidade no fornecimento de energia elétrica para os consumidores.

A tese defendida neste trabalho é que as concessionárias de distribuição devem considerar as características técnicas especificas de seu sistema elétrico, utilizando uma racionalidade técnica e econômica, visando aperfeiçoar a utilização dos seus recursos. Com a utilização de métodos de otimização, procura-se conjugar a busca pela eficiência, e os estímulos econômicos conseqüentes, com a qualidade de fornecimento, na forma das normas estabelecidas pelo órgão regulador, a ANEEL.

O objetivo geral da pesquisa é desenvolver metodologia para formação de conjuntos de consumidores e suas metas de continuidade, de forma a permitir o reagrupamento dos consumidores da concessionária em conjuntos, de maneira a minimizar o risco de multa por ultrapassagem dos índices de continuidade, buscando respeitar as solicitações de qualidade de fornecimento impostas pela agência reguladora. Os objetivos específicos são: analisar os aspectos de qualidade de energia elétrica referente à continuidade do fornecimento; analisar o comportamento de algoritmos de otimização aplicados a problemas não polinomiais (NP) que se apresentou na reconfiguração dos agrupamentos dos consumidores.

1.3 METODOLOGIA

Como metodologia, foram estabelecidas três etapas para alcançar os objetivos deste trabalho. Em primeiro lugar, foi realizada uma pesquisa qualitativa, de horizonte longitudinal dos aspectos relacionados à continuidade de fornecimento dos serviçços públicos de energia elétrica e esta é primeira grande contribuição desta Tese. A

[10] Depois de alguns anos de experiência na análise e auditoria dos dados de continuidade das empresas, existe um consenso dentro da ANEEL que os valores de metas são elevados, e as multas aplicadas às concessionária são pequenas, o que implicou na reformulação da Resolução ANEEL 024/2000.

contextualização das normas no tempo, a comparação entre elas e a apresentação de suas vantagens e limitações representa um esforço que deverá servir de base para outros estudos nesta área.

Como passo seguinte foram analisados a formação dos principais agrupamentos de consumidores de uma concessionária de distribuição de energia elétrica, e os problemas advindos da lógica de agrupamento desses conjuntos de consumidores.

Na abordagem teórica adotada nesta tese são utilizados os conceitos, modelos matemáticos e as técnicas de solução de alguns algoritmos de otimização evolutivos. A aplicação destes algoritmos antes restrita aos meios acadêmicos é cada vez mais comum no cotidiano das organizações. Foram utilizados neste trabalho algoritmos genéticos e algoritmos imunológicos.

Outra grande contribuição deste trabalho foi a utilização de algoritmos evolutivos em problema de explosão combinatória, a análise do desempenho dessas ferramentas de otimização e a comparação do desempenho entre os algoritmos genéticos e o algoritmo de seleção clonal para um problema de grande complexidade computacional. Esta comparação é apresentada no trabalho e é possível identificar os ganhos relativos de cada um dos Algoritmos.

1.4 ESTRUTURA DA TESE

Além da presente introdução, esta tese está estruturada em mais seis capítulos. No segundo capítulo serão apresentados os conceitos sobre qualidade de fornecimento de energia elétrica, a evolução da regulamentação no Brasil, além da revisão bibliográfica do problema enfrentado no trabalho.

No terceiro capítulo será apresentado o referencial teórico da otimização, especificando os conceitos técnicas e algoritmos utilizados. No quarto capítulo, apresenta-se a metodologia proposta para resolução e em seguida, os resultados das simulações para o caso estudado, no quinto capítulo. O sexto capítulo apresenta

a extensão da metodologia proposta para o caso de conjuntos de consumidores definidos de forma geoelétrica, como determina a Resolução Normativa 395/2009 da ANEEL que define cada conjunto de consumidores como sendo a área de abrangência de cada Subestação de Distribuição. Finalmente, no último capítulo, são destacadas as principais conclusões do trabalho, apresentando as considerações finais e temas para futuros desenvolvimentos.

2 QUALIDADE NO FORNECIMENTO DE ENERGIA ELÉTRICA CONTINUIDADE DO SERVIÇO

A Constituição de 1988 determina o formato mais geral da forma de exploração dos serviços públicos, conforme abaixo:

> "Art. 175. Incumbe ao poder público, na forma da lei, diretamente ou sob regime de concessão ou permissão, sempre através de licitação, a prestação de serviços públicos.
> Parágrafo único. A lei disporá sobre:
> I - o regime das empresas concessionárias e permissionárias de serviços públicos, o caráter especial de seu contrato e de sua prorrogação, bem como as condições de caducidade, fiscalização e rescisão da concessão ou permissão;
> II - os direitos dos usuários;
> III - política tarifária;
> IV - a obrigação de manter serviço adequado."

Especificamente quanto à qualidade dos serviços públicos a Lei 8.987, de fevereiro de 1995, que dispõe sobre o regime de concessão e permissão da prestação de serviços públicos previsto no art. 175 da Constituição Federal, determina sobre prestação adequada do serviço que:

> "CAPÍTULO II - Do Serviço Adequado
> Art. 6º Toda concessão ou permissão pressupõe a prestação de serviço adequado ao pleno atendimento dos usuários, conforme estabelecido nesta lei, nas normas pertinentes e no respectivo contrato.
> § 1º Serviço adequado é o que satisfaz as condições de regularidade, continuidade, eficiência, segurança, atualidade, generalidade, cortesia na sua prestação e modicidade das tarifas.
> § 2º A atualidade compreende a modernidade das técnicas, do equipamento e das instalações e a sua conservação, bem como a melhoria e expansão do serviço.
> § 3º Não se caracteriza como descontinuidade do serviço a sua interrupção em situação de emergência ou após prévio aviso, quando:
> I - motivada por razões de ordem técnica ou de segurança das instalações; e,
> II - por inadimplemento do usuário, considerado o interesse da coletividade.

Sabe-se que o fornecimento de energia elétrica constitui um dos mais importantes serviços de utilidade pública, por afetar diretamente o cotidiano das pessoas e ser determinante para o desenvolvimento econômico do país. Esse caráter estratégico justifica a preocupação da sociedade com a qualidade desses serviços, com a criação de normas legais especificas para o tema.

A criação de indicadores foi a forma encontrada para estabelecer os níveis de qualidade em uma concessão. A determinação desses indicadores de qualidade e os valores de metas são de grande importância na determinação das tarifas, pois, quanto melhor a qualidade do fornecimento de energia elétrica, maiores os investimentos necessários implicando em uma maior tarifa para o consumidor. Por outro lado, o custo da baixa qualidade de fornecimento, também, afeta o consumidor, conforme será apresentado no item 2.2.

2.1 INDICADORES DE QUALIDADE

A exemplo das outras áreas de fabricação de produtos ou prestação de serviços, qualidade no fornecimento de energia elétrica segue os conceitos e metodologias da Total Quality Control (TQC)[11], que trouxeram um novo patamar de eficiência das empresas. A partir dela, surgiram diversas outras formas de gestão, sendo que as certificações da serie ISO 9000, tornaram-se muitas vezes obrigatórias, impondo-se como selo de qualidade para o mercado consumidor.

Em Tahan (2001) determina-se que a qualidade de fornecimento de energia elétrica deve envolver algumas dimensões:

- Produto - está diretamente relacionada à satisfação do cliente é medida através das características de qualidade dos produtos e serviços;
- Serviço (fornecimento – entrega);
- Atendimento comercial:
  - Presteza;
  - Cortesia.
- Segurança - é avaliada a segurança dos colaboradores e dos usuários dos produtos. No caso da distribuição de energia elétrica, este é um ponto

[11] Segundo CAMPOS (1992), para que a satisfação das necessidades dos clientes sejam atendidas, a qualidade total se relaciona às seguintes dimensões: qualidade intrínseca, custo, atendimento, moral e segurança.

importante, pois a distribuição de energia através de redes aéreas são uma constante ameaça a vida;

- Eficiência - a entrega de produtos ou serviços finais ou intermediários deve ser realizada na quantidade, na data e no local certo;
- Atualidade – está relacionada à evolução tecnológica dos equipamentos que podem fornecer ou requerer níveis diferenciados de qualidade do produto;
- Modicidade – deve-se buscar a qualidade do produto sem onerar excessivamente o consumidor.

O processo de controle do órgão regulador através de indicadores pode ser entendido como o de "controle por resultados". A sua filosofia uma sistemática de apuração dos indicadores, seguida da comparação com padrões e finalmente uma política de conseqüências, com a determinação de penalidade, e/ou reparos.

Deste modo a qualidade do serviço pode ser controlada (monitorada) por indicadores que retratam a qualidade da atividade do serviço público[12]. Tais indicadores devem ter as seguintes características:

- Significado para o consumidor - Deve captar os aspectos, etapas e resultados essenciais ou críticos do serviço, ter período de apuração bem definido, definição sobre a sua abrangência: coletivos e ou individuais e facilidade de ser comparável;
- Viabilidade de apuração - Devem ser apurados pelas concessionárias de modo acurado, rotineiro e fáceis de compreender e aplicar com e baixo custo de obtenção;
- Viabilidade de fiscalização e validação – Os processos nos quais são obtidos os indicadores devem ser auditáveis. A rastreabilidade do processo, desde a obtenção do registro e adequada manutenção dos dados, e sua restituição são importantes na acreditação dos resultados e na transparência para a sociedade;

[12] Segundo Hassim (2003), é essencial na geração de um indicador de qualidade de um produto ou serviço, no caso particular, energia elétrica, levar em consideração como o cliente percebe o serviço que lhe está sendo prestado ou produto que lhe está sendo fornecido. A capacidade de proporcionar satisfação às necessidades do cliente é o principal fator a ser considerado na geração dos indicadores técnicos de qualidade.

- Flexibilidade e robustez – O indicador deve permitir investigar uma ampla gama de situações relevantes, pequenas modificações não devem mudar substancialmente os resultados, e devem ser suficiente/estatisticamente representativo;

A determinação de padrões e metas a serem seguidos, sempre é um processo difícil para a agência reguladora e concessionária, em qualquer área de atividade. Existe consenso que as tarifas devem refletir a qualidade do serviço prestado. Sob este aspecto, a determinação dos indicadores de qualidade acima ou abaixo da capacidade de realização destes indicadores pelo concessionário trará um sobrepreço para o consumidor.

No caso de indicadores muito restritos, os investimentos necessários trarão uma elevação na tarifa, na próxima revisão tarifária, de forma inversa, quando os indicadores de qualidade são inferiores aos possíveis de serem realizados, o consumidor já estaria pagando por uma tarifa superior à necessária. Na determinação dos padrões e metas algumas variáveis devem ser levadas em consideração:

- Estágio tecnológico - É tecnicamente possível atingir as metas? Sabe-se que o sistema elétrico brasileiro, em sua grande parte, é aéreo, estando sujeito às forças da natureza. Enfim, um sistema subterrâneo poderá ter indicadores de qualidade muito superiores, já que está protegido e sua estruturas não estão tracionadas;
- Investimentos necessários - O indicador é economicamente alcançável? Quanto custará ao consumidor ter este indicador de qualidade? Existe disponibilidade de recursos?
- Período de tempo - Quanto tempo será dado para objetivo ser alcançado ou uma melhoria em relação ao padrão?
- Benchmark – O padrão e/ou meta é comparável? Existe situação referencial para comparação?

Nas últimas revisões tarifárias observou-se uma tendência para negociação dos indicadores de qualidade, entre as agências e concessionários. Esta postura, a

princípio mais flexível, em um segundo momento torna-se um problema de *Moral Hazard*[13], passível de punição sem que a concessionária possa se defender.

Finalmente, no processo de controle do órgão regulador existe uma política de conseqüências, que normalmente são as penalidades que podem ser uma simples advertência até a perda da concessão. Em postura mais moderna em relação às penalidades, espera-se que o órgão regulador aplique penalidades somente no último caso. Normalmente o Termo de Ajuste de Conduta (TAC) é utilizado para sanar problemas de qualidade com os consumidores.

A qualidade do produto ou sua conformidade para o setor elétrico é representado pelo grau de perfeição com que a onda de tensão é disponibilizada para os consumidores. Inicialmente foi traduzido pela conformidade dos níveis de tensão e a continuidade do fornecimento de energia elétrica[14].

A regulamentação da qualidade do serviço no setor de energia elétrica, no Brasil, foi iniciada pelo Departamento Nacional de Águas e Energia Elétrica (DNAEE), que em 1978, regulamentou a qualidade da energia quantificada pelos níveis de tensão[15], objeto da Portaria DNAEE 047/78; e pelo nível de continuidade do fornecimento, determinado pela Portaria DNAEE 046/78.

2.2 A IMPORTÂNCIA DA CONTINUIDADE DO FORNECIMENTO DE ENERGIA

A mudança promovida pela Resolução ANEEL 024/2002, também, reflete a mudança dos consumidores e da sua ciência dos direitos sociais os quais possui, dentre eles a prestação adequada do serviço de eletricidade sem a sua interrupção.

---

[13] Mas-Collel *et al* (1995) apresentam na sua definição sobre risco moral uma visão que engloba dois conceitos principais: a alteração do comportamento dos agentes e ações com elevados custos de monitoramento ou prevenção..

[14] Com a mudança da base tecnológica dos equipamentos de eletro-mecânicos para eletro-eletrônicos os fenômenos de curta duração passaram a ter grande importância na qualidade da energia.

[15] Variação da tensão de fornecimento de energia elétrica, abaixo ou acima da sua tensão de placa, reduz a vida útil e/ou contribui para o funcionamento do equipamento fora das condições de projeto.

Os trabalhos da Comissão de Serviços públicos de São Paulo (CSPE) iniciaram este novo ciclo de regulamentação, em relação a continuidade de serviço.O estudo “Avaliação do custo Social de Interrupção no Fornecimento de Energia do lado de Demanda no Estado de São Paulo”, pesquisou o valor que o consumidor estaria disposto a pagar para manter um nível mínimo de qualidade do serviço. Este indicador recebeu o nome de “custo social da interrupção” e define como reflexo dos custos diretos e indiretos de curto prazo, suportados pelo consumidor, causados por uma descontinuidade no fornecimento de eletricidade.

Para avaliação deste custo, foi desenvolvida no Estado de São Paulo uma pesquisa que tinha a meta de calcular o montante que os consumidores residenciais, comerciais e industriais estavam dispostos a pagar para evitar as interrupções. A amostra para a realização do estudo foi separada de acordo com as classes de consumo e estratificada conforme a proporcionalidade identificada no cadastro de consumidores da concessionária analisada, os quais receberam questionários específicos de acordo com a sua classificação (GOUVEA et al, 2001).

Após a aplicação dos questionários para cada um dos grupos, as informações foram tabuladas e a partir do uso de ferramentas estatísticas, tais como: cálculo de distribuições de probabilidades, análises de regressão e rotinas de ajustes de curvas. Desta forma, foi possível determinar de modo estratificado o custo da energia interrompida, considerando os aspectos sazonais e cíclicos, de acordo com o período em que a interrupção ocorre seja dia, semana ou ano. Chegou-se as seguintes conclusões, agrupadas por categoria:

- Residencial - O grupo foi estratificado em três faixas de consumo, para cada um deles foi quantificado a renda média e o custo da interrupção. A média da categoria foi de US$ 0,83/kWh, pelo método de custos diretos, o custo médio da interrupção foi de US$0,96/kWh.
- Comercial e industrial de pequeno porte - O resultado desta metodologia, considerando os processos produtivos apenas, alcançou o patamar de 1,27 US$/kWh interrompido.
- Comercial e industrial de grande porte - Esta categoria apresentou dados discrepantes quando se avaliou o consumidor comercial e industrial. Para o

primeiro, o custo médio do kWh interrompido foi de US$3,50, enquanto que o segundo, este valor aumentou para US$9,09. Destaca-se que a agroindústria foi inclusa nesta análise, como categoria industrial.

Ao final, concluiu-se que o valor do custo interrompido para a classe residencial, ponderando os estratos foi de US$0,90/kWh. Para a categoria comercial, interpolando-se os valores de pequeno e grande porte chegou-se a um resultado de US$1,70 por kWh interrompido. Já a classe industrial, também realizando ponderações com o porte dos empreendimentos, este valor alcançou US$5,3 por kWh interrompido (GOUVEA et al, 2001). Concluindo-se que os custos da interrupção de energia elétrica, para as diversas classes de consumo, são bastante superiores a tarifa praticada.

2.3 A PORTARIA Nº 046/78/ DNAEE

Em 17 de abril de 1978 foi editada a Portaria nº 046/78/ DNAEE, a primeira norma brasileira para determinar as condições técnicas e a qualidade na prestação do serviço de distribuição de energia elétrica. A Portaria teve como base o relatório SCOM 01.02 - Índices Operativos – desempenho sistema de distribuição do Comitê de Distribuição (CODI) que por sua vez utilizou a experiências das empresas convenentes na confecção do trabalho.

A portaria estabeleceu indicadores coletivos e individuais, valores máximos de duração e freqüência das interrupções fornecimento de energia elétrica e a forma de apuração e os prazos de normalização dos indicadores que ultrapassassem os limites máximos impostos para as concessionárias distribuidoras de energia elétrica.

Os indicadores individuais e coletivos padronizados refletiam o número de interrupções ocorridas e o somatório de tempo das descontinuidades de

fornecimento de energia elétrica, no período de observação. Os indicadores coletivos foram denominados de DEC e FEC[16] e estão detalhados a seguir:

- Duração Equivalente de Interrupção por Consumidor (DEC) - exprime o intervalo de tempo que, em média, cada consumidor do conjunto considerado ficou privado do fornecimento de energia elétrica, no período de observação, considerando-se as interrupções maiores ou iguais a três minutos. A apuração do DEC deverá ser efetuada obedecendo à seguinte formula:

$$DEC = \frac{\sum_{j=1}^{k} Ca(i) * t(i)}{Cc} \qquad (1)$$

Onde,

Ca - número de consumidores, do conjunto considerado, atingidos na interrupção (i).

t(i) - tempo de duração da interrupção (i), em horas

i- Índice de eventos ocorridos, no sistema que provocam interrupções em uma ou mais unidades

Cc - número total de consumidores do conjunto considerado.

- Frequência Equivalente de Interrupção por Consumidor (FEC) - exprime o número de vezes que, em média, cada consumidor do conjunto considerado ficou privado do fornecimento de energia elétrica, no período de observação, considerando-se as interrupções maiores ou iguais a três minutos. A apuração do FEC deverá ser efetuada, obedecendo à seguinte formula:

$$FEC = \frac{\sum_{j=1}^{k} Ca(i)}{Cc} \qquad (2)$$

Onde,

n - número de interrupções no período de observação

[16] No cálculo dos índices DEC e FEC são computadas todas as interrupções ocorridas em qualquer parte do sistema elétrico, independente de sua natureza – programadas ou acidentais, exceto as manobras com duração inferior a três minutos.

Ca - número de consumidores, do conjunto considerado, atingidos na interrupção (i).

Cs - número total de consumidores do conjunto considerado.

Dois conceitos importantes foram definidos na Portaria no 046/78/ DNAEE e mantidos nas atuais normas de qualidade de fornecimento. Primeiro, a apuração em separado dos indicadores coletivos por conjunto de consumidores, vinculados a uma dada área física, mas situados em áreas contíguas, cuja finalidade é estabelecer transparência ao consumidor, facilidade de fiscalização, além de uma possível lógica técnica para o concessionário ou para agência reguladora.

O outro ponto foi a diferenciação dos indicadores de qualidade levando-se em consideração a importância dos consumidores e explicitados na Tabela 02:

Tabela 02 - Valores máximos anuais de DEC da Portaria no 046/78/ DNAEE

CONJUNTO DE CONSUMIDORES	DEC (HORAS)	FEC (NÚMERO)
Atendido por sistema subterrâneo com secundário reticulado	15	20
Atendido por sistema subterrâneo com secundário radial	20	25
Atendido por sistema aéreo, com mais de 50.000 consumidores	30	45
Atendido por sistema aéreo, com número de consumidores entre 15.000 e 50.000.	40	50
Atendido por sistema aéreo, com número de consumidores entre 5.000 e 15.000.	50	60
Atendido por sistema aéreo, com número de consumidores entre 1.000 e 5.000.	70	70
Atendido por sistema aéreo, com menos de 1.000 consumidores	120	90

Fonte: Portaria no 046/78/ DNAEE

Finalmente, a Portaria no 046/78/ DNAEE estabelecia prazos para normalização dos níveis de qualidade do fornecimento, quando os valores apurados fossem superiores aos limites estabelecidos.

2.4 LIMITAÇÕES DA PORTARIA DNAEE Nº 046/78

Com a reestruturação do setor elétrico, a Portaria/DNAEE nº 046/78 tornou-se anacrônica. Diversos aspectos desta norma eram permitidos em um momento em

que o Estado era o provedor dos serviços públicos[17]. A ausência de punição pelo não cumprimento dos indicadores propostos e a falta de fiscalização que permitia que empresas determinassem o nível de qualidade de fornecimento segundo suas prioridades, são exemplos deste viés regulatório. No atual contexto regulatório, onde as concessionárias de distribuição foram privatizadas, o texto não era congruente com os interesses de um Estado regulador das dinâmicas sociais.

Tanure (2000) detalha e enumera os diversos aspectos e limitações:

- Ausência de punição - A Portaria/DNAEE no 046/78 não estabeleceu punição pelo não cumprimento dos padrões de continuidade propostos.
- Prazo para correção dos indicadores - Prazos dilatados foram arbritados, de modo que a concessionária teria 180 dias para adequar o padrão de atendimento nas áreas onde os indicadores fossem violados.
- Fiscalização – A pequena estrutura administrativa e a falta de autonomia do Departamento Nacional de Águas e Energia Elétrica (DNAEE) não permitiam acompanhar, detalhadamente, os indicadores e os procedimentos de coleta. Os recursos disponibilizados para o DNAEE eram fornecidos pelas empresas do setor e a Centrais Elétricas Brasileiras S.A (ELETROBRÁS).
- Aspectos sócio-econômicos - Considerando tratar-se de um ambiente onde a quase totalidade das empresas distribuidoras estava em mãos dos governos estaduais, não havia uma distinção dos papéis de governo empreendedor e fiscalizador. Assim, os índices apurados durante o período que antecedeu a criação da ANEEL devem ser considerados com fortes restrições, cabendo, entretanto, destacar o empenho de algumas distribuidoras em apurar corretamente estes indicadores, que eram utilizados como instrumentos de gerência do seu desempenho.

[17] È importante frisar que a Portaria 046/78/DNAEE nasceu em um momento que a expansão do sistema elétrico brasileiro era uma prioridade. Já a Resolução 024/02/ANEEL está contextualizada em um momento em que a universalização dos serviços públicos de energia elétrica estava bastante avançada, sendo portanto, possível estabelecer novos níveis de qualidade.

- Métodos de apuração - As concessionárias não utilizavam procedimentos isentos de erros para a coleta e tratamento dos indicadores de continuidade, resultando em índices apurados com baixa confiabilidade[18].
- Transparência - Os consumidores não conheciam e não reivindicavam seus direitos com relação ao padrão de qualidade do suprimento de energia elétrica.

Em Hassim (2003) acrescentam-se novos argumentos:

- Atualidade - Os padrões técnicos e de atendimento ao consumidor, estabelecidos como referenciais para a qualidade dos serviços de energia elétrica, ficaram incompatíveis com o processo de reestruturação do setor elétrico, com as novas exigências dos próprios consumidores e, com o avanço tecnológico dos equipamentos e dos processos de produção. Enfim, não existia o conceito de metas evolutivas, previamente definidas, para toda a área de concessão, que estabelecessem obrigatoriedade de melhoria nos padrões de atendimento, para todas as distribuidoras.
- Comparação - Os limites definidos para DEC e FEC na referida portaria eram incomparáveis àqueles praticados em sistemas similares da Europa, Canadá ou Japão. Além do mais, as concessionárias de energia não utilizavam a mesma metodologia de apuração desses indicadores, tornando-se difícil comparar o desempenho das mesmas.

Pode-se citar ainda:

- Novos Indicadores - Apenas o DEC e o FEC não são suficientes para tratar a questão da continuidade de fornecimento sendo necessários outros instrumentos de avaliação;

[18] Ainda segundo Tanure(2000), constatou-se a existência de conjuntos com elevado número de unidades consumidoras, que apresentavam valores nulos para os indicadores DEC e FEC para um período de três meses, significando fornecimento ininterrupto em conjuntos improváveis de se verificar tal fato. Outra inconsistência observada era a existência de conjuntos atendidos por sistemas de distribuição deficientes, radiais e longos, apresentando valores apurados dos indicadores de continuidade melhores que conjuntos formados por grandes cidades que, em geral, são atendidas por sistemas elétricos com maior grau de confiabilidade, por serem supridas a partir de sistemas redudantes, e conseqüentemente com maior flexibilidade operativa.

- Áreas homogêneas - A existência de uma tabela única com os indicadores de continuidade prevista na Portaria DNAEE no 046/78 para todas as concessionárias distribuidoras de energia elétrica do país

A partir do grupo de trabalho estabelecido na Portaria DNAEE nº 163/93 ampliou-se o escopo da Portaria DNAEE nº 046/78, estabelecendo novos atributos de qualidade que deveriam ser considerados: disponibilidade, conformidade, restaurabilidade e flexibilidade. Apresentou também novos indicadores: Duração de Interrupção por Consumidor (DIC); – Freqüência de Interrupção por Consumidor (FIC); interrupções de curta duração (ICD); e interrupções de longa duração (ILD).

Apesar de alguns avanços, as mudanças significativas vieram com a Resolução Normativa ANEEL 024/2002 que readequou, atualizou e ampliou o escopo da regulamentação de qualidade quanto à continuidade de fornecimento.

2.5 RESOLUÇÃO NORMATIVA ANEEL 024/2000

Avanços significativos foram realizados nesta resolução, principalmente quanto à penalização da concessionária pela prestação de serviços inadequados. As principais mudanças introduzidas foram:

- Ausência de punição – A partir desta resolução as concessionárias passaram a ser punidas pela falta de qualidade na prestação do serviço. A incidência de multa pelo não atendimento aos padrões determina crédito em favor do consumidor lesado na própria fatura de energia imediatamente posterior à apuração. Apesar do estabelecimento de punições, os valores das multas foram inicialmente pequenos não incentivando as empresas na redução dos indicadores. Os artigos 4º, 10º, 21º e 22º da resolução tratam de temas relacionados às punições pela violação dos padrões de continuidade.

- Transparência – Um dos aspectos relevantes para o consumidor e atendido na reestruturação do setor foi o aumento da transparência dos processos, cuja novidade mais visível são as audiências públicas. Quanto ao controle do desempenho dos indicadores de qualidade, a resolução determina que os valores apurados dos indicadores de continuidade constem das faturas de energia elétrica, juntamente com os padrões a serem atendidos. O artigo 15º versa sobre o assunto.
- Fiscalização – Segundo o artigo 4º, os indicadores de continuidade deverão ser apurados por meio de procedimentos auditáveis. Além disso, no artigo 16º, a resolução determina a criação de Sistema de Atendimento às Reclamações dos Consumidores. Assim, a concessionária de distribuição deverá dispor de sistemas ou mecanismos de atendimento emergencial, acessíveis aos consumidores, para que os mesmos apresentem suas reclamações quanto a problemas relacionados ao serviço de distribuição de energia elétrica, com serviço de atendimento telefônico gratuito, disponível todos os dias durante 24 (vinte e quatro) horas, acessível de qualquer localidade de sua área de concessão
- Métodos de Apuração - As concessionárias de distribuição deverão certificar o processo de coleta dos dados e de apuração dos indicadores individuais e coletivos estabelecidos nesta resolução, com base na norma ISO 9000 International Organization for Standardization (ISO).
- Atualidade – O estabelecimento de metas de desempenho a serem cumpridas pelas concessionárias, a cada período de revisão tarifária, representa a introdução de um novo parâmetro regulatório que deverá contribuir para a evolução do desempenho das concessionárias de distribuição. O artigo 17º toca neste ponto específico.
- Comparação – Uma das inovações da reestruturação dos setores de infra-estrutura foi a regulação por comparação ou *Yardstick competition*. Neste caso o desempenho das concessionárias é comparado através de uma referência, *benchmark*, que deve induzir a elevação dos níveis médios de continuidade, aumento de produtividade média, melhorias dos processos associado à redução de custos, e redução das assimetrias de informação, entre as agências e concessionárias. Para o estabelecimento das metas de

desempenho para continuidade de fornecimento, a resolução, em seu artigo 17º, propõe três parâmetros a serem considerados: as metas já estabelecidas em alguns contratos de concessão, o histórico de desempenho das empresas e os padrões de continuidade resultantes da análise comparativa entre as empresas.

- Novos Indicadores - A Resolução no artigo 12º, introduziu um indicador: a Duração Máxima de Interrupção Contínua por Unidade Consumidora (DMIC), que estimula a empresa distribuidora a alocar de forma mais eficaz as equipes de manutenção em sua área de concessão. A adoção de estratégias gerenciais para minimizar os tempos de interrupções impactará os valores dos demais indicadores, que deverão ser reduzidos em decorrência desta nova obrigação.

Finalmente, um dos pontos que mais diferencia as normas de continuidade de fornecimentos é do critério de formação dos conjuntos. Através da resolução, as concessionárias de distribuição podem dividir sua área de concessão em conjuntos de forma a considerar as características técnicas especificas de seu sistema elétrico, visando aperfeiçoar a utilização dos seus recursos de operação e manutenção, utilizando uma racionalidade técnica e econômica.

2.5.1 Critério de Formação dos Conjuntos

Para análise e acompanhamento dos indicadores coletivos é necessária a criação de áreas que agrupem estes consumidores. Dentro da metodologia proposta pela Resolução ANEEL 024/2000, determinou-se, por concessionária, agrupamentos de consumidores segundo critérios estabelecidos no artigo 8º da mesma resolução:

> Os conjuntos de unidades consumidoras deverão abranger toda área atendida pela concessionária, respeitadas as seguintes condições:
>
> I - quando um conjunto for subdividido/agrupado deverão ser definidos novos padrões de continuidade, levando-se em consideração o histórico existente;
>
> II - o conjunto definido deverá permitir a identificação geográfica da localização das unidades consumidoras; e

> III - não poderão ser agrupadas, em um mesmo conjunto, unidades consumidoras situadas em áreas não contíguas .

A partir dos conjuntos de consumidores verifica-se o desempenho das concessionárias distribuidoras de energia. Os conjuntos deverão permitir a identificação geográfica da localização das unidades consumidoras e não poderão ser agrupadas áreas não contíguas. Essa restrição na formação dos conjuntos visa facilitar a fiscalização das metas de qualidade.

A relativa flexibilidade da formação dos conjuntos não deve atrapalhar o processo de análise dos indicadores de qualidade. Neste caso, é fundamental a comparação dos indicadores de qualidade em áreas com aspectos sociais, econômicos e técnicos semelhantes.

Por esta razão, a ANEEL definiu como estratégia agrupar conjuntos semelhantes e estabelecer para cada agrupamento metas de qualidade que fizessem com que, no final de um horizonte, estes conjuntos tivessem desempenho semelhante ao primeiro decil do agrupamento.

2.5.2 Metodologia de controle do desempenho de continuidade

A metodologia de controle do desempenho utilizada para fazer o acompanhamento dos eventos relacionados aos indicadores individuais e coletivos adotados é explicitada a seguir:

1. As concessionárias apresentam seus conjuntos de consumidores, segundo análise de seus técnicos;
2. Definem-se os atributos que descrevam as características dos conjuntos considerados;
3. Formam-se os agrupamentos das diversas concessionárias segundo programa computacional de análise de *clusters*;
4. Formados os *clusters*, identificam-se os conjuntos de melhor desempenho de cada agrupamento, considerando-se o DEC e FEC de cada conjunto;

5. Com base no desempenho do primeiro decil de um dado *cluster*, define-se o desempenho a ser estabelecido para os demais conjuntos do mesmo *cluster*;
6. A partir dos indicadores coletivos são estabelecidas metas individuais de continuidade DIC e FIC

A figura 1, apresenta visualmente a metodologia de formação dos conjuntos e suas metas de continuidade, estabelecida na Resolução Normativa ANEEL 024/2002:

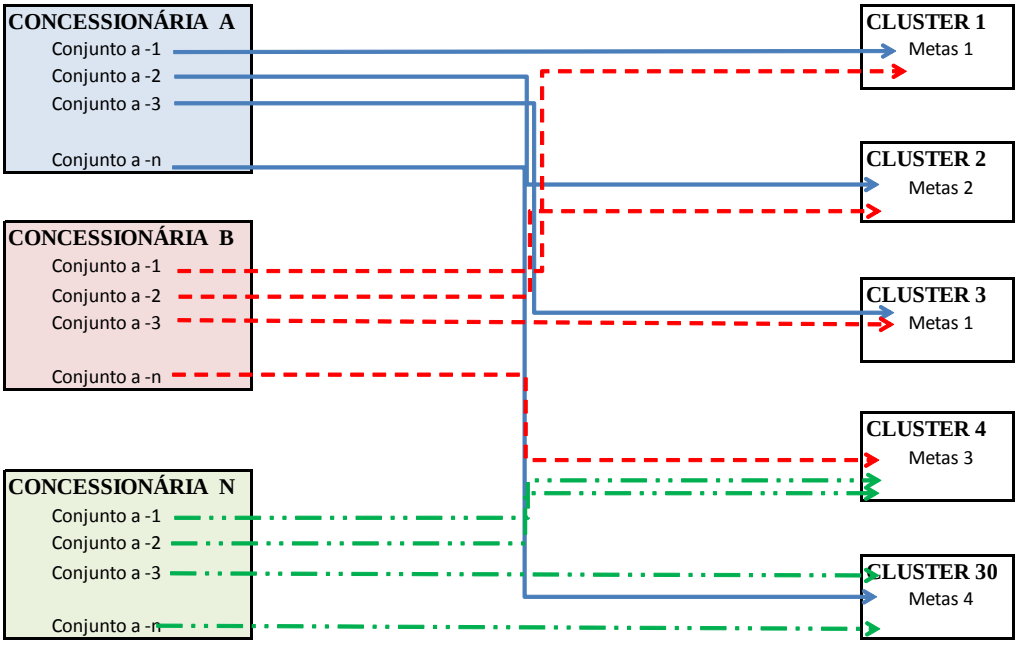

Figura 1 - Metodologia de formação dos conjuntos e suas metas de continuidade

Conforme visto anteriormente, a análise dos indicadores coletivos de continuidade é realizada a partir da formação dos diversos conjuntos de consumidores de uma área geográfica dentro de uma concessão. Assim, com base nesses diversos conjuntos das concessionárias, a ANEEL poderá realizar a regulação por comparação.

A ferramenta escolhida para comparação do desempenho dos diversos conjuntos de consumidores no Brasil foi a análise de agrupamentos ou *clusters analysis*. Esta técnica permite agrupar os diversos conjuntos das várias concessionárias a partir de parâmetros preestabelecidos. O objetivo é criar agrupamentos com características semelhantes.

Segundo Tanure (2000), cada *cluster* representa o agrupamento de elementos semelhantes, com base em um conjunto de variáveis descritivas de cada um destes

elementos. Inicialmente, para identificar os agrupamentos a serem formados na análise de *clusters*, ocorre o estabelecimento dos parâmetros. Deve-se observar que a escolha destas variáveis é o ponto crítico da técnica de análise.

No estudo de Tanure (2000), mais de vinte atributos foram inicialmente considerados. Porém, devido às dificuldades na obtenção de vários destes atributos, optou-se por cinco atributos básicos na elaboração do estudo:

1. Área de cada conjunto, em km^2 ;
2. Extensão da rede primária, em km;
3. Potência Instalada, em kVA;
4. Número de consumidores;
5. Consumo médio mensal, em MWh.

Tomando-se os valores de cada um dos atributos acima listados como coordenadas em cinco dimensões de cada ponto, pode-se determinar a localização destes conjuntos, conforme tabela 03.

Tabela 03 - Atributos dos diversos conjuntos

Conjunto	Km^2	Km	kVA	Ncons	kWh
1	X_1	Y_1	Z_1	W_1	C_1
2	X_2	Y_2	Z_2	W_2	C_2
3	X_3	Y_3	Z_3	W_3	C_3
...					
N	X_n	Y_n	Z_n	W_n	C_n

Fonte – (TANURE, 2000)

Na determinação dos agrupamentos é necessário calcular as distâncias entre todos os elementos dos conjuntos. Uma das formas é através do critério da distância Euclidiana. A distância Euclidiana entre os pontos “1” e n é definida como:

$$D(1,n) = \sqrt{(X_1 - X_n)^2 + (Y_1 - Y_n)^2 + (Z_1 - Z_n)^2 + (W_1 - W_n)^2 + (C_1 - C_n)^2} \qquad (3)$$

Conhecidas as distâncias entre todos os conjuntos, o próximo passo é separar os conjuntos em grupos. Dois métodos de classificação formal de agrupamentos são usualmente utilizados, o hierárquico e o não hierárquico. Em Tanure (2000) apresentam-se maiores detalhes sobre as escolhas envolvendo a Teoria de Agrupamentos ou *Clusters Analysis*.

A ANEEL realizou o agrupamento de todos os conjuntos (4.135) de todas as concessionárias de energia elétrica do país em apenas 30 *clusters*, utilizando

método de classificação não hierárquico, de maneira que cada *cluster* contém conjuntos de diferentes concessionárias, tornando possível utilizar o modelo de *Yardstick Competition*[19].

2.5.3. A formação das metas coletivas dos conjuntos

No modelo proposto, define-se uma meta por *cluster* que deve ser alcançada por todos os conjuntos que pertencem a este *cluster*. A metodologia utilizada definiu a meta como sendo o primeiro decil da distribuição de indicadores dos conjuntos daquele *cluster*[20]. Desta maneira, espera-se que dentro de um intervalo de tempo definido, todos os conjuntos cujos indicadores se encontram além deste valor, obtenham a melhora de desempenho necessária para atingir a meta estabelecida para o *cluster*. O Gráfico 1 ilustra o estabelecimento de limites para um conjunto de um dado *cluster*, para o indicador DEC. O mesmo procedimento é feito para o indicador FEC.

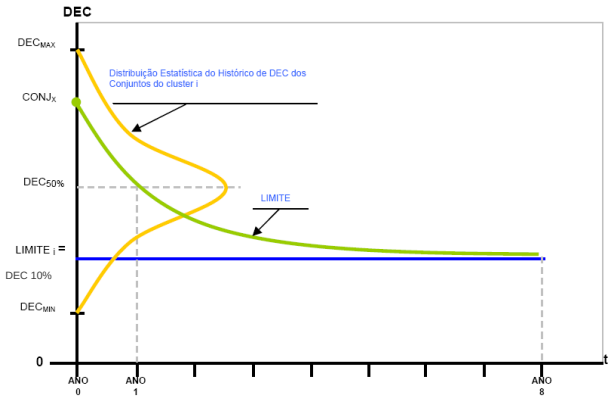

GRÀFICO 1: Definição do limite de DEC para um conjunto de um cluster
Fonte: Nota Técnica nº 0028/2010-SRD/ANEEL

As multas por ultrapassagem dos indicadores individuais são definidas de acordo com as metas dos indicadores coletivos de cada conjunto. Como o DIC e FIC

[19] Técnica de regulação por comparação, a qual pode utilizar a média, o melhor ou um conjunto dos melhores desempenhos como parâmetro para a equiparação.

[20] Exemplo: para os conjuntos da COELBA, as metas de DEC e FEC dos conjuntos foram determinadas a partir de suas características e de acordo com a divisão definida pela COELBA, uma vez que essas características definiram os *cluster*s aos quais cada conjunto pertence. A divisão por municípios levou os 418 conjuntos da COELBA a serem classificados em 9 *cluster*s.

determinarão o DEC e FEC do conjunto, a definição ótima do conjunto é a daquele formado por consumidores cujo desvio padrão dos DIC e FIC seja pequeno, caso contrário há o risco dos consumidores, cujos valores de DIC e FIC sejam muito superiores ao valor médio do conjunto, sofram multas por ultrapassagem dos indicadores individuais.

Desta forma, os conjuntos devem ser definidos de maneira a possuir o mesmo nível de qualidade no atendimento, pois isso será refletido nos indicadores individuais. Sendo assim, em princípio, áreas próximas aos centros de operação devem ser desagregadas de áreas distantes dos sistemas de suporte.

Por exemplo, a divisão por municípios não atende a este critério. De maneira geral, as áreas urbanas e rurais dos municípios apresentam níveis de atendimento diferentes, de maneira que, se o DEC e FEC forem calculados levando em consideração a característica dos consumidores (rurais ou urbanos), os valores são bastante diferentes, assinalando uma possibilidade de multa superior a que seria esperada se os consumidores tivessem características de atendimento semelhantes.

A lógica de formação dos conjuntos por municípios não leva a uma racionalidade econômica, já que concessionária e consumidores ficam em um impasse. Ou aumenta-se o número de turmas para atendimento aos consumidores rurais, elevando-se os custos de O&M, ou a concessionária pagará multas para o consumidor, sem que necessariamente esteja gerenciando mal a operação e manutenção na sua área de concessão.

Em Strauch (2005), é apresentada análise da formulação de Agrupamentos, como parte inicial dos estudos de redifinição dos conjuntos de consumidores. Este trabalho apresenta uma metodologia para minimizar o conflito explicado no parágrafo anterior.

2.5.4 Penalidades previstas

Quando transgredidos os padrões estabelecidos para os indicadores, serão aplicadas penalidades, que no caso de violação de um único consumidor deve ser calculada conforme abaixo:

Para o DIC:

$$Penalidade = \left(\frac{DIC_V}{DIC_p} - 1 \right) * DIC_P * \frac{CM}{730} * kei \tag{4}$$

Para o DMIC:

$$Penalidade = \left(\frac{DMIC_V}{DMIC_p} - 1 \right) * DMIC_P * \frac{CM}{730} * kei \tag{5}$$

Para o FIC:

$$Penalidade = \left(\frac{FIC_V}{FIC_p} - 1 \right) * FIC_P * \frac{CM}{730} * kei \tag{6}$$

onde,

DICv - Duração de Interrupção por Unidade Consumidora, verificada no período em horas e centésimos de hora;

DICp - Metas de continuidade estabelecidas no período para o indicador de Duração de Interrupção Individual em horas e centésimos de hora;

DMICv - Duração Máxima de Interrupção Contínua, verificada, por interrupção, em horas e centésimos de hora;

DMICp - Metas de continuidade estabelecidas para o indicador, por interrupção, em horas;

FICv - Freqüência de Interrupção por Unidade Consumidora verificada, em número de interrupções por período;

FICp - Metas de continuidade estabelecidas no período para o indicador de Freqüência de Interrupção por Unidade Consumidora, em número de interrupções por período;

CM - Média aritimética do valor das faturas mensais do consumidor afetado , relativas às tarifas de uso, referentes aos 3 (três) meses anteriores à ocorrência;

730 - Número médio de horas no mês; e

kei = Coeficiente de majoração, que variará de 10 a 50, e cujo valor, fixado inicialmente em 10 (dez), poderá ser alterado pela ANEEL a cada revisão ordinária das tarifas.

Os valores das multas devem ser integralmente repassados para o consumidor afetado pela interrupção.

2.6 CONCLUSÕES DO CAPÍTULO

A edição da Resolução ANEEL nº 024, de 27 de janeiro de 2000, a Agência Nacional de Energia Elétrica – ANEEL atualizou a regulamentação no tratamento dos aspectos relativos à continuidade do fornecimento de energia elétrica, tendo como referência o novo contexto regulatório, estabelecido com a reestruturação dos serviços públicos de energia elétrica

A resolução permite que as concessionárias agrupem unidades consumidoras, considerando as características técnicas especificas de seu sistema elétrico, utilizando uma racionalidade técnica e econômica, visando aperfeiçoar a utilização dos seus recursos, e considerando sua capacidade de prover condições de atendimento de forma homogênea.

3 ALGORITMOS DE OTIMIZAÇÃO

Em Sistemas Elétricos de Potência (SEP), a utilização de otimização é bastante difundida, devido à natureza dos problemas enfrentados, com grandes quantidades de variáveis e soluções possíveis para um dado problema. A complexidade dos problemas implica em resoluções não óbvias e a impossibilidade de utilização da intuição e/ou experiência do analista, ou ainda, devido à velocidade necessária para manter a operação de sistemas em tempo real[21].

Neste capítulo, pretende-se apresentar as técnicas de otimização utilizadas para resolver o problema de redistribuição de consumidores, previstos na Resolução ANEEL nº 024/2000, discutida no capítulo anterior.

3.1 O PROBLEMA DE OTIMIZAÇÃO

Como alocar recursos limitados entre atividades (ou decisões) competidoras de maneira “ótima”, levando em consideração as diversas restrições possíveis ? Esta é a síntese de um problema de otimização.

Em Hillier (1986) é apresentado o rezoneamento escolar na cidade de Middletown, nas escolas de 2º grau, com a finalidade de atingir um balanceamento racial, de negros e brancos, levando em consideração a distância percorrida pelos alunos até a escola, dividindo-se o município em 10 áreas. A tabela 04, resume os dados do problema:

Tabela 04 – Dados para o estudo de rezoneamento escolar de Middletown

ÁREA	Nº DE ALUNOS BRANCOS	Nº DE ALUNOS NEGROS	DISTÂNCIA ESCOLA 1	ESCOLA 2	ESCOLA 3
1	300	150	1,2	1,5	3,3
2	400	0	2,6	4,0	5,5
3	200	300	0,7	1,1	2,8
4	0	500	1,8	1,3	2,0
5	200	200	1,5	0,4	2,3
6	100	350	2,0	0,6	1,7
7	250	200	1,2	1,4	3,1
8	300	200	3,5	2,3	1,2
9	150	250	3,2	1,2	0,7
10	350	100	3,8	1,8	1,0
	Capacidade máxima por escola		1500	2000	1300

Fonte : HILLIER (1986)

O primeiro passo em um problema de otimização é identificar/definir claramente as variáveis de decisão. Neste caso, após deliberações decidiu-se que o objetivo geral seria minimizar a soma das distâncias percorridas pelos alunos, colocando nas restrições o balanceamento racial pretendido. Assim, o problema foi formulado da seguinte forma:

Sendo $\chi_{i,j}$ = número de estudantes da área i designado para escola j (i =1,2,..,10; J =1,2,3). A função objetivo seria Minimizar

$$Z = 1{,}2\ \chi_{1,1} + 1{,}5\ \chi_{1,2} + \ldots + 1{,}0\ \chi_{10,3} \qquad (7)$$

Evidente, que a a alocação dos estudantes deverá atender, os limites físicos de capacidade e/ou restrições diversas, que modificam os resultados implicando em um direcionamento dos alunos entre as diversas opões de escola. O estabelecimento das restrições, ou espaço de soluções, está relacionado com a disponibilidade de vagas da escola e o balanço racial. As restrições são:

1. Designação da área

$$\chi_{1,1} + \chi_{1,2} + \chi_{1,3} = 450 \qquad (8)$$
$$\chi_{2,1} + \chi_{2,2} + \chi_{2,3} = 400 \qquad (9)$$

$$\chi_{10,1} + \chi_{10,2} + \chi_{10,3} = 450 \qquad (10)$$

2. Capacidade da escola:

$$\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1} \leq 1500 \qquad (11)$$

[21] A utilização de técnicas de otimização deverá ser ainda maior com a sofisticação dos sistemas, principalmente com a introdução dos conceitos de Smart Grid.

$$\chi_{1,2} + \chi_{2,2} + \ldots + \chi_{10,2} \leq 2000 \quad (12)$$

$$\chi_{1,3} + \chi_{2,3} + \ldots + \chi_{10,3} \leq 1300 \quad (13)$$

3. Balanceamento Racial

$$[(300/450)\ \chi_{1,1} + (400/400)\ \chi_{2,1} + \ldots + (350/450)\ \chi_{10,1}] \div [\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1}] \geq \theta^{22} \quad (14)$$

$$[(300/450)\ \chi_{1,1} + (400/400)\ \chi_{2,1} + \ldots + (350/450)\ \chi_{10,1}] \div [\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1}] \leq 1 - \theta^{23} \quad (15)$$

$$[(150/450)\ \chi_{1,1} + (0/400)\ \chi_{2,1} + \ldots + (100/450)\ \chi_{10,2}] \div [\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1}] \geq \theta \quad (16)$$

$$[(300/450)\ \chi_{1,2} + (400/400)\ \chi_{2,2} + \ldots + (350/450)\ \chi_{10,2}] \div [\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1}] \leq 1 - \theta \quad (17)$$

$$[(150/450)\ \chi_{1,3} + (0/400)\ \chi_{2,3} + \ldots + (100/450)\ \chi_{10,3}] \div [\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1}] \geq \theta^{24} \quad (18)$$

$$[(300/450)\ \chi_{1,3} + (400/400)\ \chi_{2,3} + \ldots + (350/450)\ \chi_{10,3}] \div [\chi_{1,1} + \chi_{2,1} + \ldots + \chi_{10,1}] \leq 1 - \theta \quad (19)$$

Em seguida, chega-se a etapa onde se define a técnica matemática de otimização adequada**.** Alguns fatores deverão nortear esta escolha:

- Linearidade da função objetivo – A ausência de linearidade exclui, a princípio, a possibilidade de utilização da Programação Linear;
- Complexidade computacional do modelo – Algumas técnicas não podem ser utilizadas em todos os problemas devido ao grande tempo de solução dos problemas o que as torna inviáveis na prática;
- Número de Estágios – Em alguns problemas existe a necessidade de incluir vários estágios, o que pode determinar a técnica a ser utilizada.
- Modelagem do problema - Um ponto importante e quase nunca explicitado nos textos de otimização é a formulação do modelo matemático de otimização. A modelagem do problema pode inviabilizar a utilização da técnica/método de otimização, como se verá no capítulo 4 deste trabalho.

Fica evidente que, apesar das simplificações, pelo valor das variáveis não serem inteiras, este problema pode ser resolvido com a utilização da Programação Linear.

Segundo Kagan e Bento (2009), as técnicas utilizadas para o tratamento dos problemas nos Sistemas Elétricos de Potência (SEP) podem ser divididas em: técnicas baseadas em métodos de otimização clássicos de programação

[22] Representa a fração mínima de estudantes brancos na escola 1
[23] Representa a fração máxima de estudantes brancos na escola 1
[24] Representa a fração mínima de estudantes negros na escola 3

matemática[25]; Modelos Híbridos que utilizam-se de heurísticas associadas a modelos de programação matemáticas; Técnicas de Inteligência Artificial[26].

O problema de redistribuição de consumidores é considerado um problema matemático complexo. A resolução por métodos aplicados à Programação Linear e/ou Programação Inteira pode resultar em valores incompatíveis e/ou não garante a convergência em um tempo razoável (CARVALHO FILHO, 2008).

Segundo Kagan e Bento (2009), os métodos exatos de solução de problemas Programação Linear e Programação Inteira normalmente utilizam-se de heurísticas que consomem grande quantidade de memória e tempo de processamento, o que levou ao desenvolvimento de algoritmos aproximados, nos quais não se garante a determinação da solução ótima, sendo adequados para problema de grande escala. A seguir o problema de complexidade de um algoritmo será melhor detalhado.

3.2 COMPLEXIDADE DE UM ALGORITMO

Um programa computacional eficiente, escrito corretamente, pode ter aplicação real limitada ou inviabilizada, devido ao tempo de processamento ou à quantidade de memória necessária para armazenar os dados e variáveis envolvidas.

A construção de algoritmos eficientes é de grande importância e objeto de estudo na Engenharia da Computação. Em Cormel (2002), apresenta-se o seguinte exemplo:

> "Você tem a sua disposição um computador que executa 1 milhão de instruções por segundo, e outro supercomputador que executa 100 milhões de instruções por segundo. Agora suponha que se implemente um programa eficiente com tempo $T(n)=2n^2$ para ser executado no Supercomputador. Supondo também que você implemente um outro programa o MergeSort com tempo $T(n)=50n\log n$ para ser executado no computador mais lento. Com estes dados, vamos calcular o tempo que cada

[25] As técnicas/métodos de Programação Matemática são: Programação Linear; Programação Inteira; Programação linear inteira mista; Programação não linear; Programação Dinâmica.

[26] As principais técnicas/métodos de Inteligência Artificial atualmente utilizadas, são: Sistemas Especialistas; Redes Neurais Artificiais. Mineração de dados, Métodos de Busca Heurísticas, Algoritmos Genéticos, Recozimento Simulado, Colônia de Formigas etc.

programa leva no respectivo computador para ordenar 1 milhão de números.

$$Supercomputador \rightarrow \frac{2(10^6)^2 \, instruções}{10^8 \, instruções / segundo} = 20.000 segundos \cong 5{,}56 hs$$

$$ComputadorLento \rightarrow \frac{50(10^6)\log(10^6) instruções}{10^6 \, instruções / segundo} = 1.000 segundos \cong 16{,}7 \min$$

Conclui-se que apesar de um computador ser 100 vezes superior ao outro, a utilização de algoritmo mais eficiente determina o tempo de execução de um algoritmo, que representa o número de operações primitivas ou passos executados, é um dos requisitos para determinar a função complexidade de tempo. Ainda segundo Cormel (2002), um problema de ordenação, utilizando um algoritmo *InsertSort* possui um tempo de execução que para o melhor caso seria T(n)= an+b, para uma seqüência de dados já ordenada. Já para uma seqüência não ordenada este tempo de execução seria uma função polinomial T(n)= an^2+bn+c. Na prática, o interesse é a definição da maior ordem, pois esta define o comportamento assintótico do algoritmo. Desta forma, o algoritmo *InsertSort* é O(n^2), ou seja, O grande de n^2, ou ordem de n^2, implicando que, quando o número de entradas n é grande, a função complexidade de tempo é quadrática.

Os algoritmos de otimização utilizando programação matemática empregam grande parte dos recursos da máquina, além de um tempo maior de execução em relação aos programas menos complexos. Em muitas aplicações reais a utilização de algoritmos de otimização não são viáveis, ou existe uma razão específica para sua utilização.

Em Strauch ET al. (2005), é apresentado problema de priorização de investimentos em melhoramentos de sistemas de distribuição, que escolhe os investimentos que serão realizados em redes secundárias de distribuição, levando em consideração o retorno e custos das obras, dentro de um valor teto de orçamento. O método *Branch-and-Bound* foi escolhido para resolução do problema. A principal restrição ao uso da técnica de *Branch-and-Bound* é o grande tempo de computação requerido. Teoricamente, o acréscimo de mais um projeto, dobra o tempo de processamento. Assim, à medida que o número de projetos cresce, o tempo necessário ao processamento aumenta de forma quadrática evidenciando uma característica O(n^2), conforme Gráfico 02.

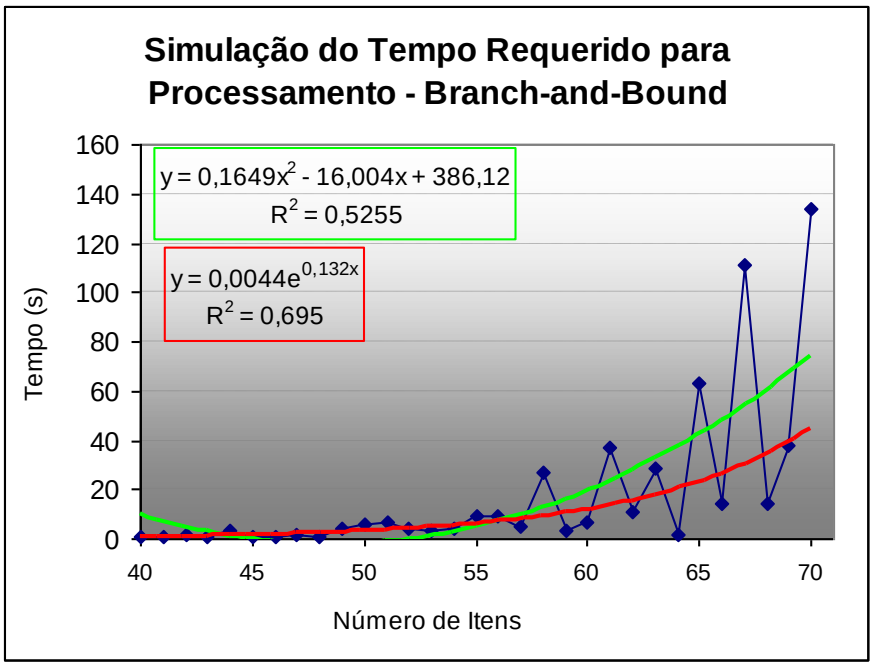

Gráfico 02– Crescimento do tempo de processamento a partir do número de itens de entrada
Fonte: (STRAUCH ET al, 2005)

Na utilização da metodologia/software pela concessionária de distribuição, notou-se uma tendência utilização de um tempo extremamente elevado de processamento ,quando o número de melhoramentos excedia aos 1.000 projetos, surgindo a necessidade de utilização de outra técnica de otimização.

O problema enfrentado neste trabalho é um problema de particionamento de áreas, conforme apresentado no item 2.6. Este problema possui função complexidade de tempo elevada, já que na medida em que o número de partições aumenta o número de possibilidades de agrupamentos cresce de forma explosiva, conforme gráfico 03.

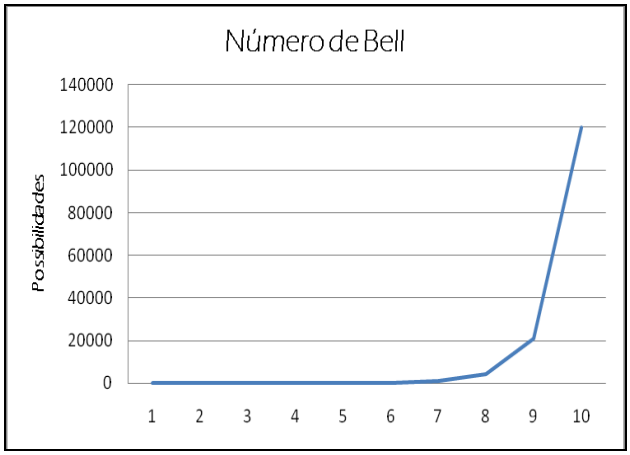

Número	
itens	Partições
1	1
2	2
3	5
4	15
5	52
6	203
7	877
8	4.140
9	21.147
10	119.975

Gráfico 03 – Crescimento de partições – Número de Bell

Este é um problema não polinomial - NP[27,28], e é intratável através de algoritmos de programação matemática, a partir de duas dezenas de partições. Segundo Castro (2001), a utilização de técnicas de algoritmos evolutivos[29] em problemas combinatoriais deve-se a excelente capacidade de exploração do espaço de soluções, além de reduzir o esforço computacional em memória e/ou tempo de processamento necessários para resolver este tipo de problema. Assim, a decisão foi utilizar técnicas de computação evolutiva baseados em metáforas biológicas.

Algoritmos Evolutivos são aqueles que se utilizam das metáforas e mecanismos da evolução biológica. A possibilidade de modelar a natureza trouxe para estes modelos a capacidade de resolver problemas de alta complexidade, com muita simplicidade. Esta facilidade de implementação e utilização trouxe uma rápida disseminação na utilização destes algoritmos, cujo modelo mais difundido é o AG.

Outros algoritmos evolutivos baseados em metáforas espelhadas na natureza estão sendo utilizadas, a exemplo dos Sistemas Imunológicos Artificiais (SIA), que apesar de ter uma clara e intuitiva aplicação em programas antivírus em computadores, possui um desempenho semelhante a outros métodos de otimização.

A seguir serão apresentados dois tipos de algoritmos evolutivos utilizados neste trabalho: os AG e os SIA, especificamente o Algoritmo de Seleção Clonal (ASC), e como serão utilizados para solução do problema de otimização dos conjuntos de consumidores.

---

[27] A função assintótica do número de Bells é dada por $NBell = \frac{1}{\sqrt{n}}\left[\lambda(n)\right]^{n+\frac{1}{2}} e^{\lambda(n)-n-1}$

[28] Na teoria da complexidade computacional, NP é o acrônimo em inglês para Tempo polinomial não determinístico (Non-Deterministic Polynomial time) que denota o conjunto de problemas que são decidíveis em tempo polinomial por uma máquina de Turing não-determinística. A importância desta classe de problemas de decisão é que contém muitos problemas de busca e de otimização para onde se deseja saber se existe uma solução. Nesta classe está o problema do caixeiro-viajante (também chamado de problema do agente de vendas ou problema do vendedor viajante) onde se quer saber se existe um caminho ótimo que passe por todas as interpolações de um certo grafo,

[29] Diversos métodos, técnicas e sistemas de inteligência artificial buscaram inspiração na natureza. As Redes Neurais Artificiais, a otimização através da metáfora da Colônia de Formigas, simulated annealing, Enxame de Partículas e os Algoritmos evolutivos são exemplos de adaptação destas metáforas.

3.3 ALGORITMOS GENÉTICOS

Algoritmo Genético é uma técnica de otimização evolutiva, baseada na teoria da evolução das espécies e seu conceito de sobrevivência do mais forte, e têm sido aplicados com sucesso para resolver muitos problemas NP *hard* (GILL et al.,2009).

De forma geral, a partir de uma população inicial de indivíduos que simulam possíveis soluções que são avaliadas e ranqueadas a partir da necessidade/objetivo do processo e através do cruzamento da população por processos aleatórios/probabilísticos, nos quais os indivíduos mais adaptados devem passar sua informação genética a próxima geração, simulando uma evolução.

De outra forma, a evolução geralmente se inicia a partir de um conjunto de soluções criado aleatoriamente e é realizada por meio de gerações. A cada nova geração, a adaptação de cada solução ou indivíduo na população é avaliada, os indivíduos mais adaptados para o objetivo da função estudada devem ter maiores chances de serem selecionados para a próxima geração, e sofrem cruzamento e/ou mutação, que são operadores que simulam a natureza para formar uma nova população. Após várias gerações, um indivíduo é determinado como o mais adpatado ou a solução ótima do processo analisado.

Numa utilização mais abrangente do termo, um algoritmo genético é qualquer modelo baseado em população que utiliza operadores de seleção e recombinação para gerar novos pontos amostrais em um espaço de busca, conforme figura 02:

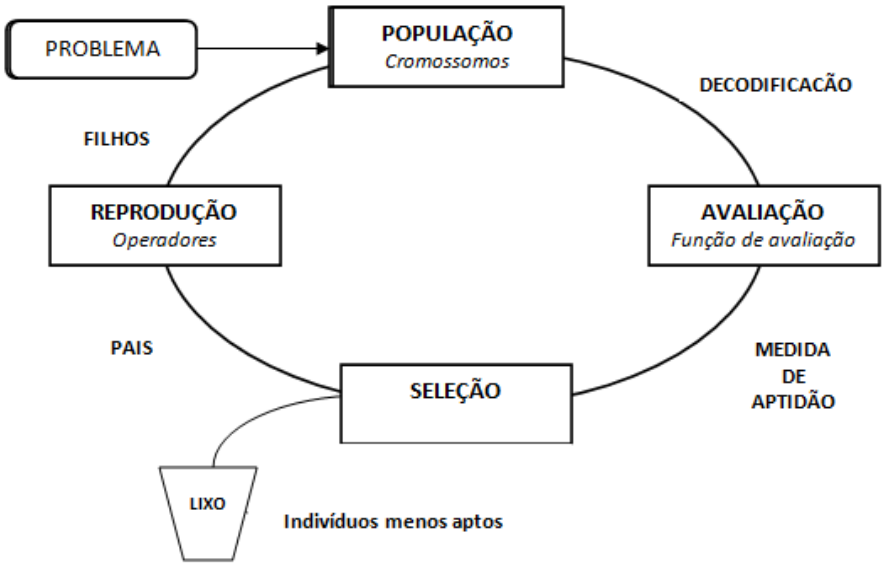

Figura 02 – Modelo genérico de algoritmo genético
Fonte: Carvalho, (1999)

Inicialmente, os AG foram introduzidos em uma perspectiva experimental. Ao passar do tempo estes passaram a ser utilizados como ferramenta de otimização. Algoritmos genéticos diferem dos algoritmos tradicionais de otimização. Kagan et al (2008) aponta os seguintes aspectos:

- Baseiam-se em uma codificação do conjunto das soluções possíveis, e não nos parâmetros da otimização em si;
- Os resultados são apresentados como uma população de soluções e não como uma solução única;
- Não necessitam de nenhum conhecimento derivado do problema, apenas de uma forma de avaliação do resultado;
- Usam transições probabilísticas e não regras determinísticas.

Em Ludermir (2004) outros pontos são alcançados:

- A partir de um problema de otimização, mesmo que se desconheça o que se está otimizando, é possível encontrar uma ótima solução, através dos Algoritmos Evolutivos e suas variações. Ou seja, tais algoritmos podem trabalhar em cima de problemas, sem que exista um conhecimento explícito, ou que seja necessário explicitar totalmente as funções de restrição e otimização do problema;

- Utiliza apenas informações de custo e recompensa. Não requer nenhuma outra informação auxiliar;
- São facilmente hibridizados com outras técnicas;
- Funcionam com parâmetros contínuos ou discretos;
- Resolve problemas difíceis de otimização, quando não existe nenhuma outra técnica especifica para resolver o problema;
- Aplica-se a otimização de funções numéricas em geral;
- Aplica-se a Otimização de problemas não lineares;
- Resolvem problemas de otimização com explosão combinatória.

3.3.1 O indivíduo/solução

Em AG, um indivíduo é uma representação do espaço de busca do problema a ser resolvido, em geral na forma de seqüências de bits, que podem assumir o valor 0 ou 1. Utilizando a metáfora da evolução genética cada bit representaria um cromossomo. Cada indivíduo deve representar uma resposta/solução possível para o problema.

Para exemplificar utiliza-se o problema de Priorização de Investimentos em Melhoramentos de Sistemas de Distribuição, apresentado Strauch et al. (2005), que propõe o problema de escolha dos projetos A, B, C e D, considerando o maior retorno levando-se em consideração um orçamento máximo de $40. Neste caso o indivíduo seria uma *string* com 4 bits, sendo que o valor 1 indicaria a opção de realizar o investimento, inversamente ao valor zero. Assim o indivíduo da tabela 05, representa uma solução onde somente os investimentos A e C seriam realizados:

Tabela 05 – Representação binária de um indivíduo.

	A	**B**	**C**	**D**
Indíviduo	1	0	1	0

Outro exemplo de indivíduo ocorre em um problema de Minimização das Perdas Elétricas, apresentado em Kagan et al (2008), onde duas fontes de energia elétrica atendem uma carga:

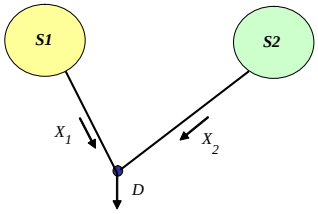

Figura 03 – Exemplo de Sistema Elétrico de Minimização das Perdas com duas fontes
Fonte: (KAGAN E BENTO, 2009)

A função otimização deste problema é:

$$\min\ p_{tot} = r_1 X_1^2 + r_2 X_2^2$$
$$s.a. \qquad X_1 + X_2 \geq D$$

Em AG, as soluções possíveis podem ser representadas através de *string*, que são os valores de X_1 e X_2 expressos em base binária, conforme figura 04:

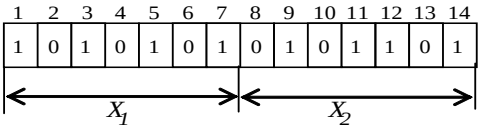

$$X_{1,i} = \frac{\left(2^0\, bit_{i,1} + 2^1\, bit_{i,2} + 2^2\, bit_{i,3} + 2^3\, bit_{i,4} + 2^4\, bit_{i,5} + 2^5\, bit_{i,6} + 2^6\, bit_{i,7}\right)}{\left(2^7 - 1\right)} X_{\max}$$

$$X_{2,i} = \frac{\left(2^0\, bit_{i,8} + 2^1\, bit_{i,9} + 2^2\, bit_{i,10} + 2^3\, bit_{i,11} + 2^4\, bit_{i,12} + 2^5\, bit_{i,13} + 2^6\, bit_{i,14}\right)}{\left(2^7 - 1\right)} X_{\max}$$

Figura 04 – Representação binária de Indivíduos Númericos
Fonte: (KAGAN et al, 2009)

Indivíduos mais complexos podem ser encontrados em Araújo et al. (2008) no projeto de pesquisa “Metodologia de Planejamento de Subestações Urbanas”[30.] Que teve como principal objetivo, desenvolver metodologia e ferramenta computacional que possibilitasse a automatização da elaboração do plano de investimento em novas Subestações de distribuição das áreas urbanas de forma otimizada, utilizando técnicas de otimização.

[30] O projeto "Metodologia de Planejamento de Subestações Urbanas – P&D 0047 - 013 / 2006" integra o Programa Anual de P&D - Pesquisa e Desenvolvimento Tecnológico do Setor Elétrico Brasileiro, instituído pela ANEEL, desenvolvido pela COELBA nos ciclos 2005 – 2006 e 2006 - 2007. O projeto foi executado através de convênio firmado entre a Companhia de Eletricidade do Estado da Bahia (COELBA) e a Universidade de Salvador (UNIFACS).

Cada Indivíduo possui cromossomos que representam a região elétrica, estas possuem suas subestações, transformadores e alimentadores, tanto os existentes como os planejados.

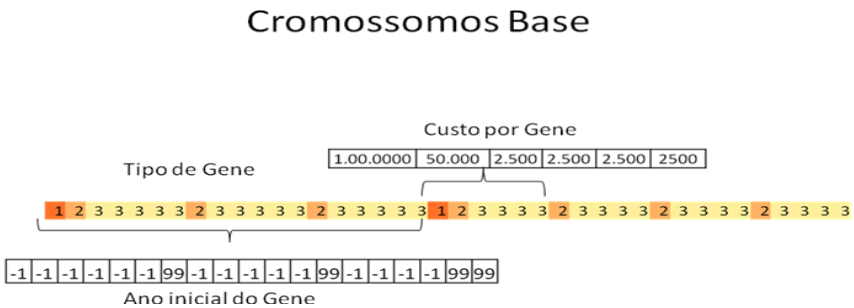

Figura 05: Modelagem de Indivíduos com Estrutura de Dados.
Fonte (ARAÚJO et al., 2008)

Resumindo, em AG o indivíduo pode ser representado de várias formas:

- Vetores de reais, (2.345, 4.3454, 5.1, 3.4);
- Cadeias de bits, (111011011);
- Vetores de inteiros, (1,4,2,5,2,8);
- Outra estrutura de dados.

3.3.2 População inicial

O tamanho da população é um parâmetro crítico no desempenho do AG. Uma população inicial muito pequena impõe uma convergência para soluções de ótimos locais, por outro lado uma população inicial muito grande determina um esforço computacional desnecessário.

Segundo Lobo e Lima (2005), existe uma dificuldade em fazer uma estimativa sobre os problemas do mundo real e, portanto, muitos usuários acabam utilizando uma chamada "*norma setting*" (50-100 indivíduos), supondo um número, ou fazendo algumas experiências com uma série de diferentes tamanhos para ver qual delas funciona melhor. Nesta mesma referência analisa-se o trabalho teórico existente sobre o dimensionamento da população inicial e acerca de diversas técnicas que

têm sido desenvolvidas para ajustar/reduzir o tamanho da população durante o funcionamento do AG..

3.3.3 A função avaliação

É outro ponto crítico na convergência do prematura do AG. O problema reside na determinação do indivíduo ou solução que mais se ajusta à resolução do problema e que, ao longo da geração, concorra/ajude a determinar o ponto ótimo da função analisada. A função avaliação pode ser: igual à função objetivo (raramente usado na prática); resultado da linearização da função objetivo; ou baseada no *ranking* do indívíduo da população (LUDERMIR, 2004).

O valor de uma função de avaliação aplicada a cada indivíduo, pode ser chamada de Aptidão ou *Fitness*. A avaliação é feita através de uma função que melhor representa o problema e tem por objetivo fornecer uma medida de aptidão de cada indivíduo na população corrente, que irá dirigir o processo de busca. É comum que esta aptidão seja calculada através da função objetivo, que depende diretamente do problema. No caso da questão que envolve a Figura 04, encontrados em Kagan e Bento (2009), o objetivo é a minimização de perdas, então a função objetivo é o cálculo das perdas no sistema apresentado.

Apesar de fornecer uma medida de apitdão clara, somente esta não levará o AG a encontrar a solução/indivíduo ótimo do problema, pois a melhor solução para o problema, assim posto, são valores de corrente igual a zero. Desta forma a inclusão das restrições do problema deve ser considerada. Segundo Kagan et al (2008):

> “Apesar de aparentemente ser obvio que um projeto não possa ter soluções inviáveis isso não é uma regra para o algoritmo genético onde um individuo é gerado a partir de sorteio que torna suas características o mais aleatórias possíveis. O algoritmo busca que o cromossomo seja uma solução para o sistema, porém essa condição não pode ser assegurada, pois apesar dos indivíduos gerados serem viáveis eles podem não satisfazer o crescimento da demanda de energia. Não seria interessante que o software gerar opções que não fossem reais, pois esses indivíduos além de ocupar lugar de possíveis indivíduos corretos ainda têm maior chance de gerar indivíduos inadequados para as próximas gerações e ainda a dificuldade de mensurar

a capacidade do individuo através de uma função avaliação, com maior esforço computacional e memória ocupada.“

Desta forma, na função avaliação, além dos custos gerados pela função objetivo devem ser acrescentadas as penalidades advindas da violação das restrições imposta pelo problema analisado.

Em alguns casos a utilização da função avaliação não tem resolução suficiente para diferenciar os melhores dos piores indivíduos, tornando a convergência lenta ou levando a soluções pobres, ou ainda pode levar à convergência prematura do indivíduo. A solução, nestes casos, é a linearização da função objetivo ou a utilização de um *ranking* para determinar a aptidão dos indivíduos/solução.

Em Kagan e Bento (2009) é oferecida solução através da normalização da função avaliação. Neste caso a nova função avaliação seria:

$$f'_{aval,i} = a.f_{aval,i} + b \tag{20}$$

Esta função determinaria o gráfico 04:

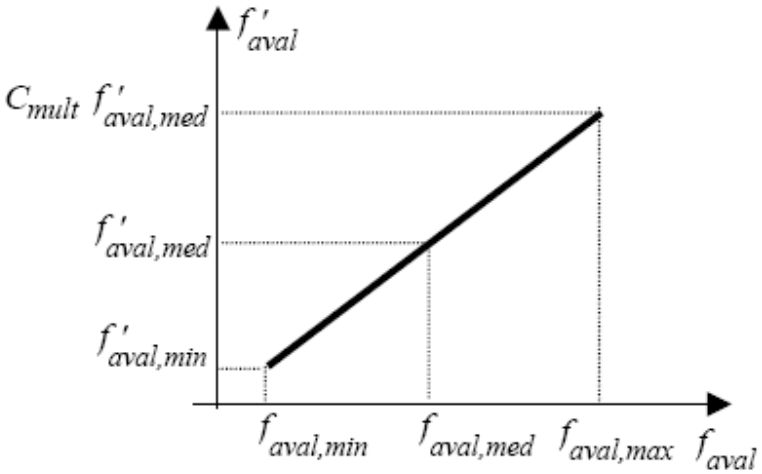

Gráfico 04 – Linearização da Função Avaliação

No cálculo dos coeficiente da reta, os valores médios da avaliação devem ser os mesmos, e a relação entre os valores máximo e médios da nova avaliação é determinada por uma constante.

Na determinação do *raking* de uma função avaliação também constrói-se uma reta para determinação da nova função avaliação, conforme mostrado no gráfico 05:

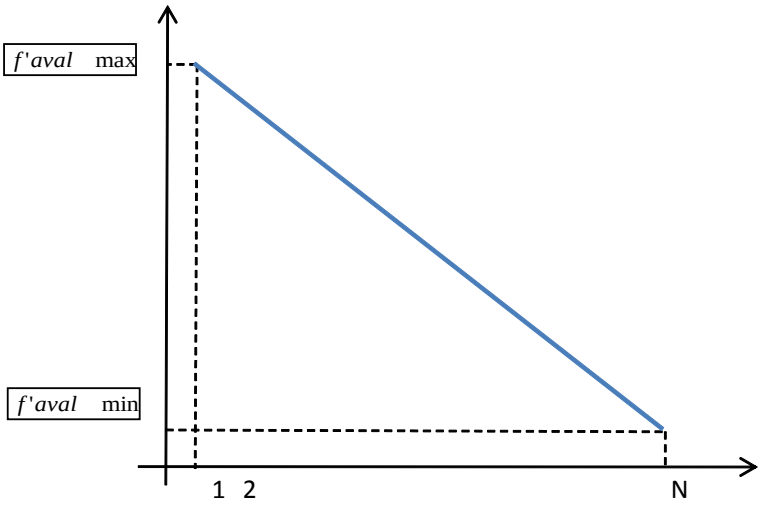

Gráfico 05 – Função Avaliação através do *ranking*.

A função é dada por

$$f\ aval(i) = f\ aval\ \min + \left(f\ aval\ \max - f\ aval\ \min\right)\frac{(N-i)}{(N-1)} \qquad (21)$$

Onde, *i* é o índice do cromossomo na população em ordem decrescente de valor da função objetivo. Segundo Lacerda (1999), o *ranking* linear requer:

- 1 ≤Max ≤2
- Max + Min = 2
- Valores bons para Max: de 1.2 a 1.5

Neste caso, e diferentemente do escalonamento linear, as probabilidades não ficam iguais, e os indivíduos mais bem avaliados apresentam uma maior probabilidade de passarem para nova geração.

3.3.4 Operadores genéticos

A seleção dos indivíduos nos AG imita a seleção natural, ou seja, os melhores indivíduos (com maior aptidão) devem ser selecionados para gerar filhos, dirigindo o AG para as melhores regiões do espaço de soluções.

No processo de seleção são utilizados alguns operadores. Os operadores genéticos são necessários para que a população se diversifique e mantenha características de adaptação adquiridas pelas gerações anteriores. Duas formas de seleção são mais utilizadas: roleta e torneio.

Em geral, usa-se a seleção por roleta, na qual os indivíduos são ordenados de acordo com a função-objetivo e lhes são atribuídas probabilidades decrescentes de serem escolhidos. A escolha é feita então aleatoriamente de acordo com essas probabilidades. Dessa forma, consegue-se escolher como pais os mais bem adaptados, sem deixar de lado a diversidade dos menos adaptados.

Neste método, cada indivíduo da população é representado na roleta proporcionalmente ao seu índice de aptidão (Figura 06). Finalmente, a roleta é girada um determinado número de vezes, dependendo do tamanho da população, e são escolhidos, como indivíduos que participarão da próxima geração, aqueles sorteados na roleta.

Indivíduo S_i	Aptidão $\int S_i$	Aptidão Relativa
S_1	2,23	0,14
S_2	7,27	0,47
S_3	1,05	0,07
S_4	3,35	0,21
S_5	1,69	0,11

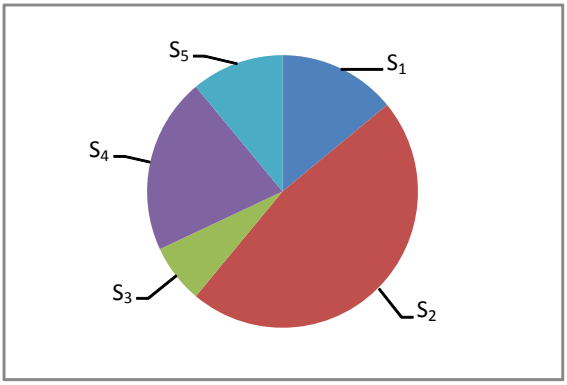

Figura 06 - Indivíduos de uma população e a sua correspondente roleta de seleção.
Fonte: (CARVALHO, 1999)

Outra forma de seleção é baseado em torneios. A seleção é feita através da criação de grupos de soluções da população; as soluções de cada grupo competem entre si, sendo que, apenas uma solução de cada grupo é selecionada (LACERDA e CARVALHO, 1999).

No torneio, seleciona-se um número de indivíduos da população que serão competidores, sendo que o número mínimo é 2 e o máximo é o tamanho da população. A Figura 07 apresenta exemplo de seleção por torneio:

Indivíduo	Fitness
X_1	200
X_2	100
X_3	9.500
X_4	100
X_5	100
X_6	10.000
X_7	1
X_8	40

Torneios		
X_1	X_7	X_8
X_2	X_3	X_5
X_6	X_4	X_4
X_2	X_7	X_1
X_5	X_5	X_5
X_3	X_4	X_2
X_4	X_2	X_6
X_4	X_6	X_5

Figura 07 - Operador Genético – Torneio.
Fonte:Linden (2008)

Em Linden (2008), são citados outros métodos: Método de Amostragem Estocástica Uniforme, Seleção Local e Seleção Truncada.

Segundo Kagan et al (2008), no AG básico, são descartados todos os indivíduos da geração anterior. Assim é comum a destruição do melhor indivíduo através do cruzamento e/ou mutação. Logo, para não peder a melhor solução encontrada, o Elitismo transfere a cópia do melhor indivíduo para a geração seguinte. Este operador tem a finalidade de aumentar a convergência do AG.

O Intervalo de Geração tem um conceito semelhante ao Elitismo e controla a porcentagem da população que será substituída durante a próxima geração. Com um valor alto, deste operador, a maior parte da população será substituída, mas com valores muito altos pode ocorrer perda de estruturas de alta aptidão. Com um valor baixo, o algoritmo pode tornar-se muito lento (LACERDA e CARVALHO, 1999).

O Cruzamento ou *Crossover* é a escolha de dois indivíduos para se reproduzirem. Este é um método que imita o processo biológico homônimo na reprodução sexuada: os descendentes recebem em seu código genético parte do código genético do pai e parte do código da mãe. A taxa de cruzamento é importante na convergência e é normalmente elevada e explicitada.

Esta operação garante que os indivíduos sejam capazes de trocar informações entre si, e gerar novos indivíduos ou explorar áreas desconhecidas do espaço de soluções. Este operador pode ser utilizado de várias maneiras; as mais empregadas são:

- Um ponto: um ponto de cruzamento é escolhido e a partir deste ponto as informações genéticas dos pais serão trocadas. As informações anteriores a este ponto em um dos pais são ligadas às informações posteriores à este ponto no outro pai, como é mostrado no exemplo da figura 08, a seguir:

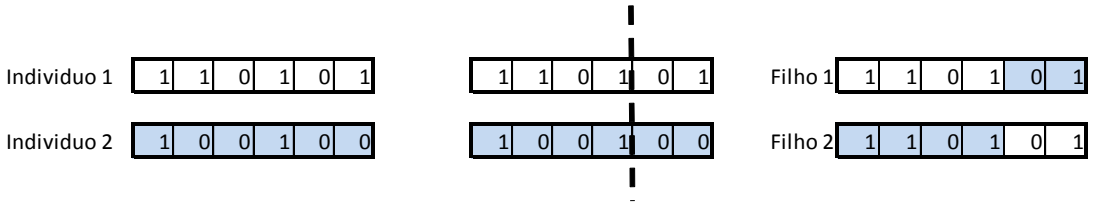

Figura 08 - Exemplo de crossover de um ponto. (a) dois indivíduos são escolhidos.(b) um ponto (4) de crossover é escolhido. (c) são recombinadas as características, gerando dois novos indivíduos.
Fonte: (CARVALHO, 1999).

- Multi pontos: é uma generalização desta idéia de troca de material genético através de pontos, onde muitos pontos de cruzamento podem ser utilizados.
- Uniforme: não utiliza pontos de cruzamento, mas determina, através de um parâmetro global, qual a probabilidade de cada variável ser trocada entre os pais.

Finalmente, o operador genético da mutação é necessário para a introdução e manutenção da diversidade genética da população, evitando convergência prematura do algoritmo e ótimos locais.

Teoricamente, a Mutação assegura a possbilidade de se chegar a qualquer ponto do espaço de soluções, além de contornar o problema de mínimos locais, pois com este mecanismo, altera-se levemente a direção da busca. O operador de mutação é aplicado aos indivíduos com uma probabilidade dada pela taxa de mutação estimada; geralmente se utiliza uma taxa de mutação pequena. A figura 09 apresenta um modelo de Mutação.

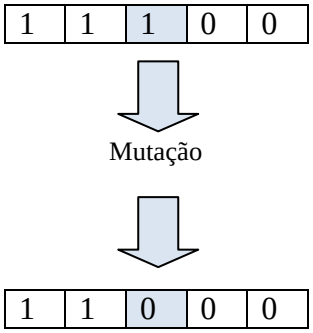

Figura 09 – Operador genético - Mutação
Fonte: (CARVALHO, 1999)

3.3.5 Critério de convergência

O gráfico 06 mostra o comportamento típico de um AG, para uma função de minimização. São apresentados a adaptabilidade média da população e do melhor indivíduo para cada geração. Neste caso, foram simuladas quinhentas gerações com 10% de mutação e apenas o indivíduo mais apto é passado diretamente para a próxima geração através do Elitismo. Para evitar a convergência da população e um mínimo local, colocou-se uma taxa de mutação que pode ser observada pela grande variação da média de adaptabilidade da população.

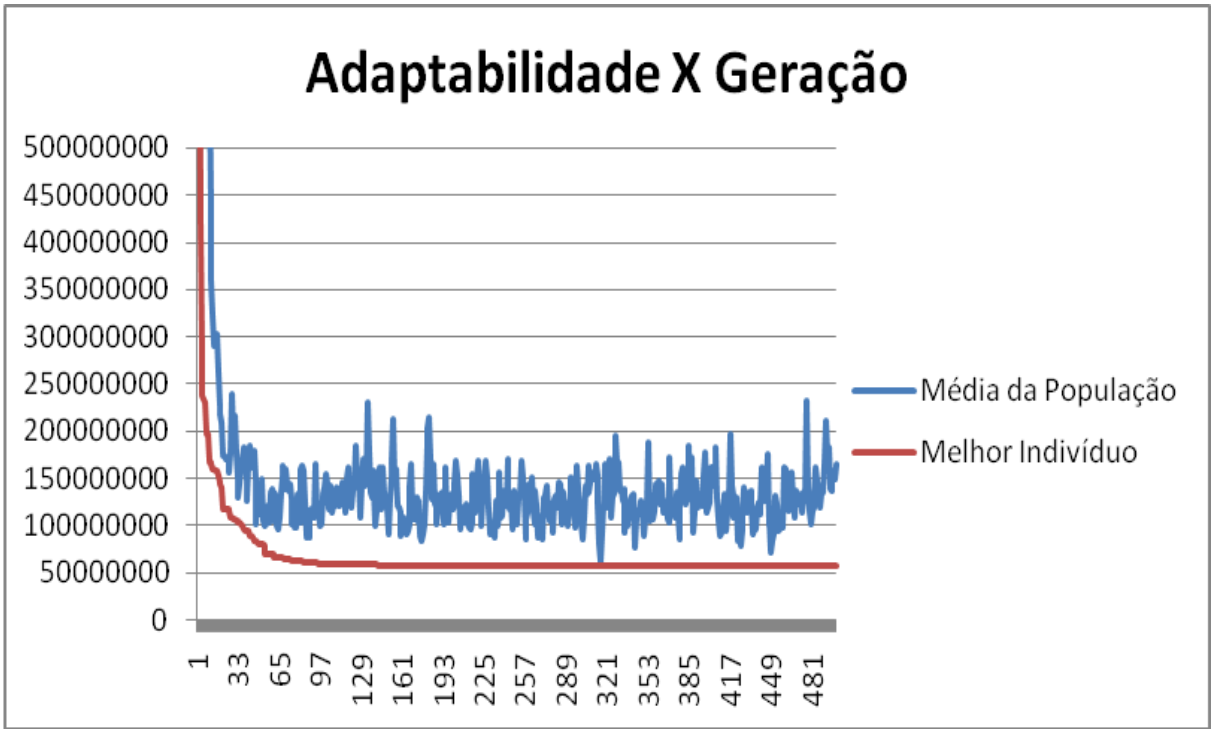

Gráfico 06: Adaptabilidade por geração.
Fonte: (ARAÚJO et al., 2008)

Ao final da simulação, o Algoritmo deverá convergir reduzindo a diferença entre o valor mínimo e o valor médio.

Os critérios de convergencia e /ou parada, mais comuns, são:

- É encontrada uma solução que satisfaz um requisito pré-definido;
- Número de gerações definido;

- Se for verificado que um número n de iterações (gerações) sucessivas não conduzem a melhorias significativas;
- Tempo de execução do algoritmo.

Naturalmente, um critério baseado apenas no número de gerações não garante a obtenção de boas soluções.

3.4 ALGORITMO IMUNOLÓGICO

Nas últimas décadas, a possibilidade de utilização de novas ferramentas de diagnóstico e análise dos processos biológicos associado ao grande interesse pelo estudo de doenças, tornou mais intensos os estudos do Sistema Imunológico Humano (SIH). Laboratórios, biólogos, médicos e engenheiros procuram modelar o sistema imunológico visando entender os fenômenos observados com a finalidade de achar a cura de enfermidades. Estruturas e processos extremamente complexos vêm sendo descobertos a cada dia, dinamizando e criando um ambiente em evolução.

Genericamente, o sistema imunológico humano protege o organismo contra ataques de microorganismos externos, que causam infecções e desequilíbrios. Este sistema é composto por dois sub-sistemas, o sistema imunológico inato e o sistema imunológico adaptativo. O primeiro defende o organismo de forma semelhante para diferentes patógenos, enquanto o adaptativo combate cada patógeno de forma específica, evoluindo com o tempo, garantindo a imunidade do organismo de forma duradoura.

A partir desta generalização, o sistema imunológico humano foi sistematizado em uma serie de procedimentos matemáticos/computacionais que passaram a ser chamados de Sistemas Imunológicos Artificiais (SIA). Os estudos dos Sistemas Imunólogicos Artificiais começaram na decada de 1980 com os artigos de Farmer, Packard e Perelson (1986) e Bersini e Varela (1990) sobre redes imunológicas. A

partir dos anos 90, os Sistemas Imunológicos Artificiais foram reconhecidos como uma área de conhecimento diferente dos Algoritmos Genéticos.

Os Sistemas Imunológicos Artificiais surgiram com a tentativa de modelar e aplicar princípios imunológicos no desenvolvimento de novas ferramentas computacionais. Uma aplicação bastante difundida dos SIA está na segurança computacional, isto porque a área de segurança de redes possui uma metáfora bem aderente com o SIH, sendo responsável pela detecção de ataques e implementação de padrões de reatividade. Segundo Faleiros (2007), a expansão na utilização de redes de computadores, teve como consequência o aprimoramento e fácil disseminação de métodos invasivos, caracterizando crimes computacionais que podem resultar na perda de produtividade, da disponibilidade, na violação de informações confidenciais, entre outros.

Entretanto, as linhas de atuação nas quais os sistemas imunológicos artificiais possuem emprego são bem amplas, dando a estas aplicações uma grande versatilidade. Segundo, Castro (2001) essas linhas de atuação são:

- Reconhecimento de padrões;
- Aproximação de funções;
- Otimização de processos;
- Análise de dados e clusterização;
- Aprendizagem de máquina;
- Memórias associativas;
- Geração e manutenção de diversidade;
- Programação e computação evolutiva;
- Detecção de falhas e anomalias;
- Controle e *scheduling*;
- Segurança computacional e de rede; e
- Geração de comportamentos emergentes.

Algoritmos imunológicos são apresentados como abordagens eficientes para a solução de problemas combinatórios. A seguir são apresentados alguns trabalhos de diversas áreas em que utiliza-se SIA para otmização de processos.

Em Carvalho Filho (2008) é apresentado um problema de otimização multiobjetivo (MOP) com a finalidade de implantação de estações de radiobase. Sabe-se que a determinação da localização e da configuração de estações de radiobase envolve um número elevado de variáveis e restrições. Assim, à medida que aumenta a complexidade da rede, torna-se inadequada a adoção de métodos empíricos para o posicionamento de estações de radiobase. A utilização de SIA deveu-se ao fato de ser um problema de grande complexidade computacional.

A comparação do desempenho entre as técnicas de programação matemática, os sistemas imunológicos artificiais e a otimização por colônia de formigas para a solução de problemas de otimização dinâmica, é proposto em França (2005). Concluiu-se que o desempenho dos algoritmos bio-inspirados se mostrou superior em todos os critérios considerados para comparação dos resultados dos experimentos dirigidos pelo autor.

Novamente a comparação entre o desempenho de técnicas de otimização é alvo do artigo de Silva et al. (2010). Neste caso, compara-se sistemas imunológicos artificiais e otimização por colônia de formigas, aplicados em 14 instâncias de um problema clássico de logística reversa que é o problema de roteamento de veículos com coleta e entrega simultâneas, proposto na literatura. Na maioria dos casos, os SIA apresentaram soluções superiores à otimização por colônia de formigas.

Um trabalho bastante difundido no Brasil é a tese de doutorado de Leandro Nunes de Castro (CASTRO, 2001). Na tese, o autor pretende criar um novo modelo, mais formal e genérico, chamado de Engenharia Imunológica, cuja definição:

> A engenharia imunológica é um processo de meta-síntese, o qual vai definir a ferramenta de solução de um determinado problema baseado nas características do próprio problema, e depois aplicá-las na obtenção da solução. Ao invés de buscar a reconstrução parcial ou total do sistema imunológico tão fielmente quanto possível, a engenharia imunológica deve procurar desenvolver e implementar modelos pragmáticos inspirados no sistema imunológico que preservem algumas de suas propriedades essenciais e que se mostrem passíveis de implementação computacional e eficazes no desenvolvimento de ferramentas de engenharia (CASTRO, 2001).

As técnicas mais conhecidas de implementação de SIA são:

- Algoritmo de seleção clonal: São inspirados na teoria da seleção clonal da imunidade adquirida, neste método considera-se que apenas as células mais

adaptadas para o reconhecimento do antígeno são selecionadas para proliferar, gerando clones, incrementando sua performance contra os antígenos com o tempo. Nesses algoritmos, a reprodução é assexuada, uma das principais diferenças com o AG, cuja reprodução é sexuada. Algoritmos de seleção clonal são mais comumente aplicados aos domínios de otimização e reconhecimento de padrões, alguns assemelham-se a um algoritmo genético sem o operador de cruzamento ou crossover.

- Algoritmo de Seleção Negativa: Inspirado pelos processos de seleção positivos e negativos que ocorrem durante a maturação das células T[31]. Neste caso, os algoritmos são normalmente utilizados para criar detectores de padrão, que reconhecem os padrões normais. Os detectores gerados fazem o censoriamento e eliminam os padrões diferentes. Segundo Falheiros (2007), o principal motivador para o desenvolvimento deste algoritmo foi a necessidade de uma busca por um processo alternativo na detecção de vírus, já que os métodos tradicionais se mostravam ineficazes, principalmente devido às novas formas de vírus computacionais que estavam surgindo nos anos 90;
- Algoritmos de Rede Imune: segundo Carvalho Filho (2008), são algoritmos inspirados na teoria da rede idiotípica proposto por Niels Kaj Jerne, que descreve o sistema imune como um conjunto de células e moléculas discretas inicialmente em repouso e que são acionadas por um estímulo antigênico externo. A teoria da rede imunológica descreve o sistema imunológico como uma rede regulada de células e moléculas que se reconhecem mesmo na ausência de antígenos. Algoritmos de redes imunológica têm sido utilizados no detecção de padrões, agrupamento, visualização de dados, controle e otimização de domínios, entre outros.

[31] Dois tipos de respostas podem ser produzidas pelo sistema imunológico: a resposta imune inata e a resposta imune adaptativa ou resposta imune específica. A resposta imune inata é gerada pelo sistema imunológico inato, enquanto que as resposta imune adaptativa é gerada pelo sistema imunológico adaptativo. Ambos os sistemas dependem da atividade de glóbulos brancos (leucócitos). O sistema imunológico inato utiliza principalmente macrófagos e granulócitos (neutró_los, eosinó_los e basó_los) e o sistema imunológico adaptativo utiliza linfócitos (células B e células T), (CARVALHO FILHO, 2008).

3.4.1 Algoritmo de seleção clonal

Devido a sua simplicidade e eficácia, a teoria de seleção clonal ou teoria de expansão clonal é o conceito mais utilizado no desenvolvimento de algoritmos de otimização baseados em sistemas imunológicos artificiais. Existem semelhanças e diferenças entre algoritmos genéticos e algoritmo de seleção clonal. A principal diferença é que no primeiro a reprodução é sexuada, com populacão evoluindo, principalmente, através do operador *crossover*. Nos Sistemas Imunológicos Artificiais a reprodução é assexuada, cada filho produzido por uma célula é a sua própria cópia, processo chamado de clonagem.

Uma semelhança é que ambos os sistemas são usados nos processos de mutação para alterar os indivíduos e introduzir a variação genética a cada nova geração. Finalmente, apesar da analogia com os processos naturais, nos Algoritmos Genéticos os objetivos finais são diferentes: nos sistemas evolutivos artficiais o objetivo é convergir para um ponto considerado ótimo, enquanto na natureza a adaptação e diversidade é sempre a meta.

O princípio da teoria da seleção clonal para a modelagem computacional é a escolha e proliferação de células com alta afinidade, produzindo um rápido crescimento na população com afinidade alta, morte das células menos estimuladas (deleção clonal), maturação de afinidade, re-selecão dos clones com maior afinidades, geração e manutenção de diversidade através de processo de mutação (CASTRO 2001). A figura 10, apresenta o algoritmo simplificado de Seleção Clonal.

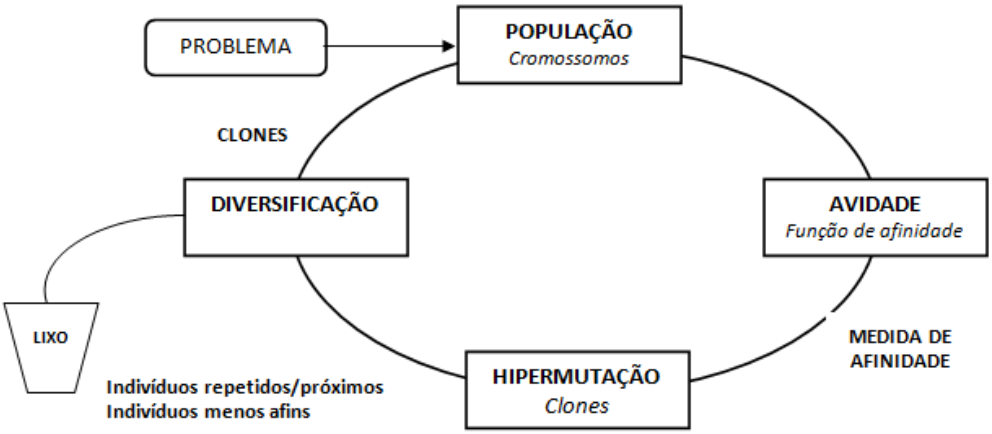

Figura 10: Diagrama de bloco do algoritmo de Seleção Clonal

Os passos do Algoritmo de Seleção Clonal são (CARVALHO FILHO, 2001):

1) Gerar aleatoriamente uma população inicial de anticorpos (soluções);
2) Selecionar os melhores anticorpos da população, baseado na medida de afinidade;
3) Reproduzir (clonar) os anticorpos da população. A quantidade de clones é inversamente proporcional a sua afinidade, formando a população de clones;
4) Submeter a população de clones a um esquema de maturação ou hipermutação proporcional a afinidade do anticorpo;
5) Re-selecionar os anticorpos, eliminando os indivíduos repetidos e/ou com afinidades muito próximas;
6) Substituir anticorpos com baixa afinidade por novos;
7) Continuar o algoritmo até atingir o critério de parada.

Resumindo, o passo inicial do algoritmo é a criação da população em que, cada anticorpo é formado aleatoriamente, garantindo uma variabilidade entre os indivíduos. Na próxima geração, apenas os melhores anticorpos, aqueles com maior afinidade serão selecionados. No algoritmo em si, os anticorpos selecionados serão copiados ou clonados e sofrerão mutações, com o propósito de melhorar a afinidade.

Para implementar o básico do sistema imunológico artificial, algumas decisões devem ser feitas: forma de representação, medida de similaridade, tamanho da população, forma de seleção (roleta ou torneio), mutação (clones por indivíduo); diversificação (taxa de supressão), e um critério de parada (número de gerações).

3.4.2 Avidade e afinidade

A exemplo dos AG, que calculam a aptidão dos indivíduos, nos SIA são calculadas a avidade ou afinidade. Utilizando-se o dicionário dos SIA, a avidade é definida como o grau de afinidade entre um anticorpo e um antígeno polivalente. A avidade representa a intensidade de ligação total entre um antígeno f(x) e um anticorpo (vetor solução x), portanto, mede a qualidade da solução candidata. As estratégias para o cálculo da avidade variam de acordo com o algoritmo utilizado (CARVALHO, 2008).

O reconhecimento do antígeno pelo anticorpo é baseado no princípio da complementaridade entre as duas moléculas. A figura 11 apresenta um exemplo de medida de avidade:

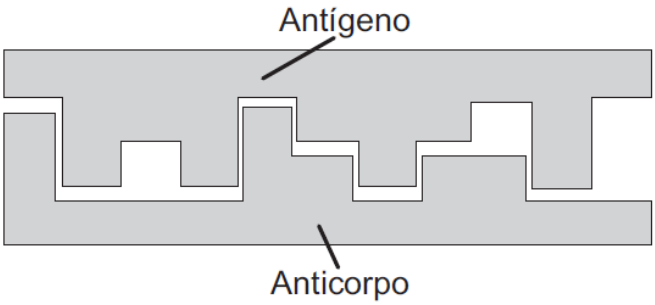

Figura 11: Regiões de complementaridade para o reconhecimento antígeno-anticorpo
Fonte: (CASTRO; TIMMIS, 2002a).

A medição da afinidade pode ser realizada de várias maneiras diferentes e depende diretamente do espaço em que se encontram as variáveis de decisão e do problema que se deseja solucionar. Quando variáveis reais são consideradas, as distâncias Euclidiana e de Manhattan podem ser utilizadas. Para uma representação binária, a distância de Hamming, a quantidade r de bits complementares consecutivos, a medida de afinidade de Hunt ou a medida de similaridade de Rogers e Tanimoto podem ser utilizadas Em Castro (2001) encontra-se maiores detalhes sobre a medição de afinidade.

No caso de otimização, o uso da função objetivo com algumas modificações é mais comum que o uso de distâncias como medida da afinidade (CARVALHO FILHO, 2008).

3.4.3 Mecanismos de seleção

Para implementar o processo de seleção proporcional a afinidade entre anticorpos e antígenos ou seleção de acordo com a avidade, os SIAs não utilizam os mesmos mecanismos de seleção comumente empregado em AG, tais como: seleção por roleta , por torneio ou ranking. Na implementação do indíviduo é clonado em vários novos indivíduos e somente um destes, normalmente o mais bem avaliado, passa para próxima geração. Existe também a possibilidade de se utilizar o elitismo, quando são escolhidos alguns indivíduos e este passam para geração seguinte. Outros métodos podem ser encontrados em Carvalho Filho (2001).

3.4.4 Proliferação e hipermutação somática

A criação de novas soluções/anticorpos é realizada por meio dos mecanismos de proliferação e hipermutação somática. A taxa de mutação é inversamente proporcional à afinidade e o número de clones é proporcional à afinidade; quando combinados conferem ao algoritmo um balanço entre mecanismo de busca local e mecanismo de busca global (CARVALHO FILHO, 2001).

Uma das principais diferenças entre os algoritmos evolutivos e os algoritmos baseados em sistemas imunológicos artificiais diz respeito ao processo de mutação. No caso de algoritmos evolutivos, a mutação é um operador secundário enquanto que nos algoritmos baseados em sistemas imunológicos, a hipermutação somática é base da sua evolução. Isto porque, nos algoritmos genéticos dois indivíduos são

cruzados para gerar um descendente, enquanto os algoritmos baseados em sistemas imunológicos artificiais realizam um tipo de reprodução assexuada, na qual um único indivíduo gera um número elevado de clones.

As técnicas de mutação empregadas dependem da representação escolhida para as variáveis de decisão. Para um espaço de Hamming, as seguintes técnicas podem ser usadas: mutação em um único ponto; mutação em vários pontos; mutação uniforme; e mutação em uma região contígua. No caso de representação real, as seguintes técnicas são aplicadas: mutação gaussiana ou indutiva; e mutação uniforme. Maiores detalhes pode ser encontrados em CASTRO (2001).

3.4.5 Diversificação

A diversificação é necessária para diminuir a probabilidade de convergência prematura e aumentar o espaço na busca de soluções nos SIA o mecanismo de busca global, ou seja, redirecionar a busca para outras regiões, adicionar novas soluções aleatoriamente. Entre os mecanismos utilizados para evitar a convergência prematura tem-se: supressão; inserção de anticorpos por recombinação gênica; e maturação fraca.

O operador de supressão é usado, quando dois anticorpos estão muito próximos, um deles pode reconhecer o outro e, por esta razão, um deles deve ser eliminado. Segundo Carvalho Filho (2008), caso a população alcance uma estabilidade em relação à qualidade das soluções propostas, a etapa de supressão realiza a eliminação de anticorpos com alto grau de afinidade entre si, possibilitando a manutenção da diversidade da população. Entre dois anticorpos com alto grau de afinidade, aquele que representa a solução de menor afinidade é eliminado.

Apesar de não ser usado neste trabalho, dois outros operadores são encontrados em Masutti (2000). A inserção de anticorpos por recombinação gênica: Caso a população não tenha atingido seu tamanho máximo, novos anticorpos são inseridos

através da recombinação de anticorpos presentes na população. Esta recombinação é feita usando cruzamento.

A Maturação Fraca se faz necessária quando nenhuma das K melhores soluções da população é aperfeiçoada durante um determinado número de gerações. Sendo assim, cada anticorpo da população é exposto ao processo de maturação fraca, que realiza alterações de forma mais eficiente que o processo de mutação.

3.4.6 Critério de parada

O número de gerações é um critério de parada muito utilizado. Outros critérios são possíveis, por exemplo: caso as K melhores soluções não sejam aprimoradas durante um determinado número de gerações, seja por seleção clonal ou maturação fraca, o critério de parada é alcançado e o processo evolutivo do algoritmo imunológico é encerrado.

O algoritmo imunológico tem um desenvolvimento muito semelhante ao algoritmo genético, porém precisa de alguns controles de evolução das gerações para verificação da convergência do algoritmo à solução do problema pesquisado.

3.5. CONCLUSÕES

A pesquisa revelou que os AG e SIA são apresentados como abordagens eficientes para a solução de problemas combinatórios. Uma grande quantidade de artigos, dissertações e teses utilizam estas ferramentas para análise de otimização de processos em diversas áreas de atuação. A bibliografia sobre Algoritmos Genéticos e Sistemas Imunológicos Artificiais foi resumida neste capitulo. Deve-se ressaltar que existe uma grande quantidade de informações que não foi descrita neste trabalho devido a extensão que seria requerida.

Os conceitos descritos neste capítulo serviram de base para construção de software que será apresentado no capítulo 05. Os algoritmos foram implementados na linguagem Java (jdk 1.6), no ambiente de desenvolvimento Eclipse. Os testes foram realizados em uma máquina com processador Intel Core 2 Quad Q8200, com 3 GB de memória RAM e sistema operacional Windows.

4 METODOLOGIA PARA REDEFINIÇÃO DE CONJUNTOS DE CONSUMIDORES

Neste capítulo apresenta-se a metodologia para formação de conjuntos de consumidores e suas metas de continuidade[32], cujo objetivo é encontrar uma forma de agrupar os consumidores da concessionária em conjuntos, de maneira que não seja indicada a realização de investimentos desnecessários, fazendo com que o risco de multa por ultrapassagem dos índices de continuidade seja minimizado e respeitando as solicitações da resolução Normativa ANEEL 024/2000 da ANEEL.

O problema de redistribuição de consumidores em conjuntos guarda grande semelhança com da redistribuição de eleitores nos distritos eleitorais, *Political Districting*, ou de alunos na escolas primárias *School Distribution*, apesar dos objetivos de cada processo serem diferentes.

4.1 REDISTRICTING

O problema que se apresenta neste trabalho, é de matemática combinatorial, e foi apresentado por Eric Temple Bell[33] e consiste no número de possibilidades de agrupamento/partições distintos, a partir de um número n de elementos de um conjunto. No exemplo a seguir, 3 elementos: (A), (B), e (C), que formam um conjunto. O conjunto de elementos da figura 12, pode ser particionado em cinco formas distintas:

[32] Esta metodologia é também apresentada no relatório final do Projeto de pesquisa “Otimização da Multa Global de Continuidade Através de Técnicas de Análises Multivariadas”, Programa de P&D da ANEEL Ciclo 2006-2007.

[33] Em matemática combinatória, O número Bell é uma homenagem a um problema de matemática combinatória, em que se determina o número de partições de um conjunto de n elementos.

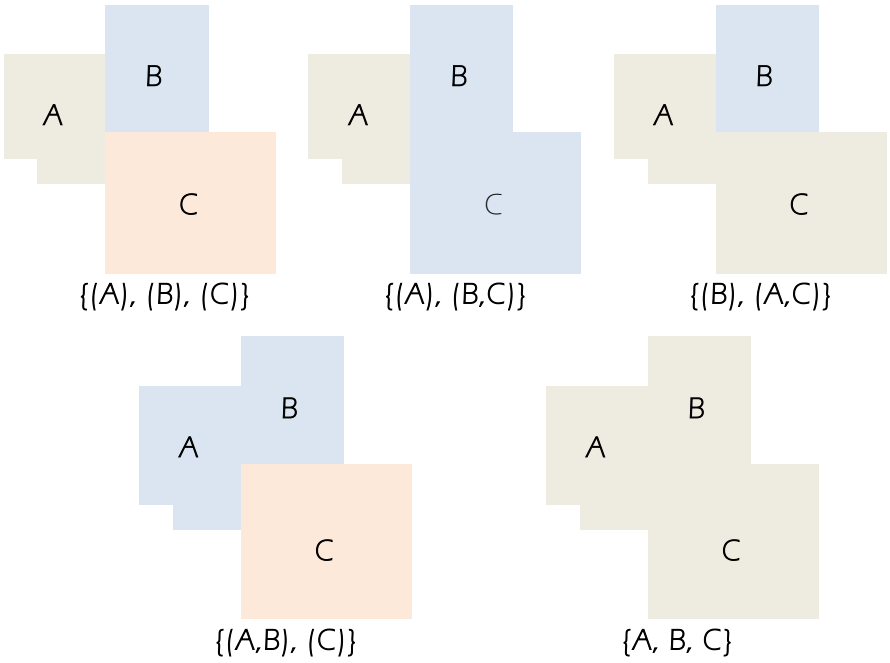

Figura 12 – Possibilidades de agrupamento de 03 áreas

No estudo, a redefinição das áreas implicará no reagrupamento em novos clusters o que determinará novas metas de continuidade individuais e coletivas. Este tipo de problema é semelhante ao chamado de Particionamento (Partitioning), e podem ser encontrados em várias áreas do conhecimento.

Uma aplicação de otimização em microeletrônica pode ser encontrada em GILL (2009). Com o avanço na tecnologia de semicondutores, houve um crescimento da complexidade no desenvolvimento de um *chip* e uma maior necessidade de integração. O particionamento do circuito é um passo importante em projeto de microeletrônica e envolve a divisão de um circuito em subpartes para facilitar o *design* e *layout*. Neste artigo, as técnicas de colônia de formigas e algoritmos genéticos são avaliadas, para resolução do problema Não Polinomial (*NP hard*). O objetivo da otimização e divisão da interligação entre as partições com a restrição de formar divisões equilibradas.dentro do *chip*.

Na Engenharia da Computação, ZHANG (2007), apresenta o desenvolvimento de projeto de sistemas embarcados, utilizando técnicas de algoritmos imunológicos. O objetivo do particionamento é determinar que cada tarefa seja executada por *software* ou *hardware*. A implementação via *software* tem um menor custo. Entretanto, exige uma necessidade de mais tempo de execução, e o inverso ocorre

com a implementação dos processos via hardware. O principal alvo de particionamento *hardware / software* é uma otimização de tempo de execução e custo do sistema embarcado.

Mais semelhante ao problema objeto do presente trabalho, em DESJARDINS et alli (2006) apresenta-se um problema de redistribuição de alunos no condado de Maryland, denominado de *School Redistricting*. O ritmo do desenvolvimento de crescimento da população exigiu a abertura de 25 novas escolas nos últimos 14 anos, o que tornou necessário a redistribuição de alunos por área de influência de cada escola. Este problema torna-se uma otimização multicritério no momento em que são considerados objetivos concorrentes, tais como: a capacidade da escola, os custos de transporte e a distribuição socioeconômica do condado. Foi utilizado o método heurístico de busca local conhecido como *hill-climbing*[34].

Outro tipo de problema bastante próximo ao proposto neste trabalho é a redistribuição de eleitores americanos chamado de *Political Distriting*. A maioria dos estados forma distritos com a finalidade de eleger um representante de cada distrito e o objetivo é dar uma neutralidade eleitoral, minimizando alguma vantagem política no reagrupamento dos eleitores. Essas vantagens podem ser: racial ou étnica, nível de renda, escolaridade, entre outros. Há três características essenciais dos distritos: devem ter populações quase iguais devem ter área contígua; e devem ser geograficamente compactos.

Em MEHROTRA (1998) apresentou-se o desenvolvimento de modelo matemático que capta as características essenciais desejáveis para uma redistribuição de eleitores, baseado em um modelo *Branch and price*.

Em ZHENPING (2007), o problema de *Political Distriting* foi modelado como um problema de partição de grafos duplamente ponderado e é formulado em modelo de programação quadrática.

[34] Em ciência da computação, *hill climbing* é uma técnica de otimização matemática que pertence à família de busca local.

Constata-se que o problema de particionamento é encontrado com razoável facilidade em várias áreas de atuação e também é resolvido através de várias heurísticas encontradas na literatura.

4.2 REGRAS PARA DEFINIÇÃO DOS CONJUNTOS DE CONSUMIDORES E METAS DE CONTINUIDADE

Quanto à formação dos agrupamentos de consumidores, a resolução ANEEL 024/2000 estabeleceu que os conjuntos de unidades consumidoras deverão abranger toda a área atendida pela concessionária, respeitadas as seguintes condições: o conjunto definido deverá permitir a identificação geográfica da localização das unidades consumidoras e não poderão ser agrupadas, em um mesmo conjunto, unidades consumidoras situadas em áreas não contíguas. As restrições iniciais na formação dos conjuntos tinham um claro objetivo da necessidade de fiscalização das metas de qualidade.

Além disso, a ANEEL determinou, quando apresentou a minuta da Resolução 024, que as concessionárias deveriam apresentar à ANEEL seus conjuntos de consumidores, como orientação, a agência reguladora afirmou que:

- Não existe número mínimo de consumidores por conjunto;
- Número máximo orientativo de 50.000 consumidores;
- Conjunto não tem vínculo com sistema elétrico;
- Deverão apresentar características homogêneas

A ANEEL, realizou o agrupamento de todos os conjuntos (4.135) de todas as concessionárias de energia elétrica do país em apenas, 30 clusters, de maneira que cada cluster contém conjuntos de diferentes concessionárias, tornando possível utilizar o modelo de *Yardstick Competition*. Para a definição dos 30 clusters, a ANEEL utilizou uma série de descritores

- km de rede primária;
- potência instalada;

- número de unidades consumidoras;
- consumo médio de cada conjunto;
- área de atendimento (km²)

No modelo proposto, define-se uma meta por *cluster,* que deve ser alcançada por todos os conjuntos que pertencem a este mesmo *cluster*. A metodologia utilizada definiu a meta como sendo o primeiro decil da distribuição de indicadores dos conjuntos daquele *cluster*.

Desta maneira, espera-se que dentro de um intervalo de tempo definido, todos os conjuntos cujos indicadores se encontram além deste valor, obtenham a melhora de desempenho necessária para atingir a meta estabelecida para o *cluster*. Obviamente, o investimento necessário para alcançar a meta será tanto maior quanto mais longe da meta do *cluster* o desempenho do conjunto estiver.

As metas de DEC e FEC dos conjuntos foram determinadas a partir de suas características (descritores) e de acordo com a divisão dos conjuntos de consumidores definido pelas Concessionárias e a divisão dos agrupamentos definidos pela ANEEL. A figura 13 apresenta/resume a definição das metas de um conjunto.

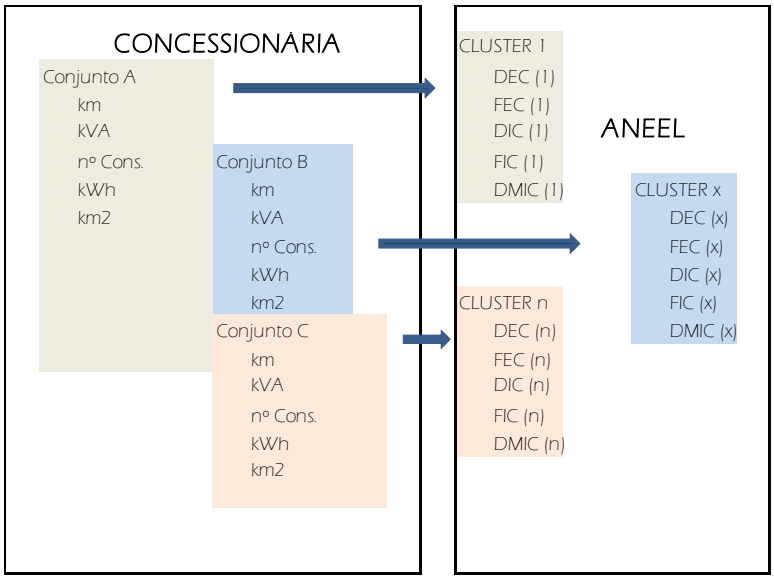

Figura 13 - Divisão conjuntos nos agrupamentos

Como não se conhecia previamente os *clusters*, nem em qual deles os conjuntos seriam agrupados, qualquer forma de divisão poderia ser uma boa escolha.

4.3 METODOLOGIA PROPOSTA

Um dos objetivos deste trabalho é desenvolver uma metodologia para reduzir o risco regulatório de multas relativas aos níveis de continuidade no sistema elétrico de uma concessionária, através do reagrupamento dos conjuntos de consumidores. Para que as possibilidades de multas sejam minimizadas deve-se procurar estratégias para formação dos conjuntos que observem tanto os aspectos relacionados aos indicadores coletivos quanto aos indicadores individuais. As multas dos indicadores individuais estão relacionadas com dois aspectos:

1. Dispersão dos indicadores DIC e FIC em um dado conjunto. Um aspecto já observado é a diferença entre os indicadores das áreas rurais e urbanas de vários conjuntos analisados.
2. Os conjuntos de consumidores estão associados a metas coletivas DEC e FEC que por sua vez apontam para metas individuais de DIC e FIC. Quanto maior os indicadores coletivos maiores os indicadores individuais, conforme pode ser observado na tabela 06:

Tabela 06– Padrões de Continuidade individuais

Faixa de variação das metas anuais de indicadores de continuidade dos conjuntos (DEC ou FEC)	Padrão de Continuidade por Unidade Consumidora Unidades Consumidoras com tensão nominal < 1kV situadas em áreas não-urbanas					
	DIC (horas)			FIC (interrupções)		
	Anual	Trim.	Mensal	Anual	Trim.	Mensal
0 -10	80	40	32	40	20	16
>10 - 20	85	43	34	50	25	20
>20 - 30	90	50	36	60	30	24
>30 - 45	100	48	40	75	38	30
>45	108	54	44	87	44	37

Fonte - Resolução no. 018/2004 ANEEL

As multas por indicadores coletivos por sua vez estão associadas ao histórico dos indicadores do conjunto e ao cluster no qual este conjunto foi agrupado. Estas duas referências formam a curva de meta dos indicadores DEC e FEC, que variam segundo a fórmula:

$$V_{ano(x)} = \left(\frac{V_{meta}}{V_{atual}} \right)^{\frac{x}{8}} \times V_{atual} \qquad (22)$$

onde

V_{meta} - Valor de meta final

V_{atual} - Desempenho atual

$V_{ano(x)}$ - Valor da meta para o ano considerado

x - Ano considerado

Assim, quanto maior o *benchmark* do *cluster,* maior será o DEC e FEC de um conjunto. Esta conclusão leva a definição de uma metodologia que mude os conjuntos de forma a modificar as metas de DEC e FEC e conseqüentemente de DIC e FIC para os consumidores do referido conjunto.

Obviamente não será possível conseguir a elevação das metas para todos os conjuntos. Alguns destes terão suas metas reduzidas, nestes casos, estes conjuntos devem ter desempenho inferior às metas e uma pequena dispersão dos indicadores.

As trocas de *clusters* em que os conjuntos estão alocados, implica necessariamente na mudança das áreas destes conjuntos, já que sua mudança reflete em todas as outras variáveis a seguir listadas: km de rede primária; potência instalada; número de unidades consumidoras; consumo médio de cada conjunto; e área de atendimento (km²).

A modificação nas configurações geográficas dos conjuntos é a forma de otimizar as metas de DEC, FEC, DIC e FIC de maneira a reduzir os riscos de multa. Enfim, a idéia central da metodologia reside na mudança de metas na medida em que mudam-se os conjuntos de consumidores, seus descritores e, consequentemente, o agrupamento e suas metas. A figura 14 apresenta uma evolução da figura 13, com a união de dois conjuntos de consumidores:

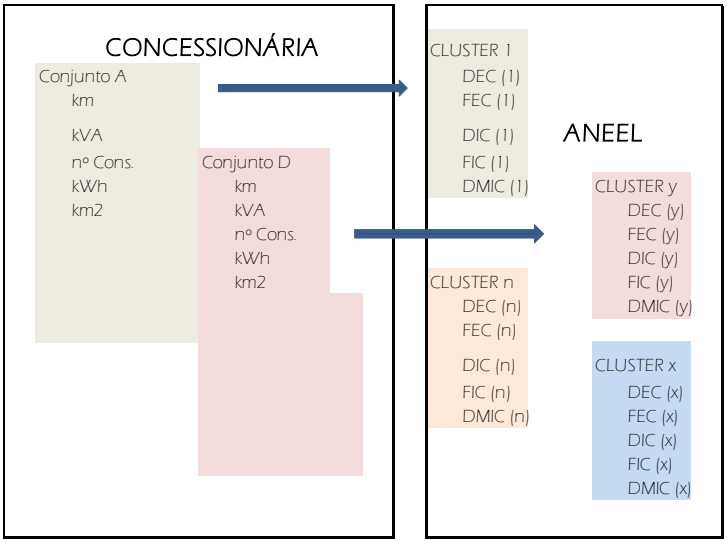

Figura 14: Novo conjunto de consumidores das áreas B + C e suas novas metas

Matematicamente pode-se definir o problema conforme equações a seguir:

$$\text{minimizar MULTAS} = \text{função}\left[\frac{\text{MetasConjunto(DIC,FIC,DEC,FEC)},}{\text{ValoresMedidos(DIC,FIC,DEC,FEC)}}\right] \tag{23}$$

onde;

$$DEC_{Meta\,do\,conjunto} = \textit{função } CLUSTER_{Conjunto}\left(\text{ValoresHistóricos}(DIC), area, km, kVA, kWh, ncons\right)$$
$$FEC_{Meta\,do\,conjunto} = \textit{função } CLUSTER_{Conjunto}\left(\text{ValoresHistóricos}(FIC), area, km, kVA, kWh, ncons\right)$$
$$DIC_{Meta\,do\,conjunto} = \textit{função } CLUSTER_{Conjunto}\left(DEC_{Metas\,do\,conjunto}\right)$$
$$FIC_{Meta\,do\,conjunto} = \textit{função } CLUSTER_{Conjunto}\left(FEC_{Metas\,do\,conjunto}\right)$$
$$km = Função[área]$$
$$kVA = Função[área]$$
$$kWh = Função[área]$$
$$ncons = Função[área]$$

sujeitas às seguintes restrições;

- Não existe número mínimo de consumidores por conjunto;
- Número máximo orientativo de 50.000 consumidores;
- Conjunto não tem vínculo com sistema elétrico;
- Deverão apresentar características semelhantes;
- Deverão apresentar pequena dispersão nos indicadores individuais.

Desta forma, a solução óbvia do problema nos leva à seguinte metodologia:

1. Calcular as multas a serem pagas, nos próximos anos de revisão tarifaria, para os atuais agrupamentos com os seus respectivos históricos de interrupções;

2. Modificar as áreas dos atuais conjuntos de consumidores de forma a criar novos conjuntos. Sugere-se limitar a divisão das áreas, repartindo-se as áreas dos municípios em rural e urbano de forma a reduzir o número de alternativas de novos conjuntos e também pela facilidade de obtenção de dados;
3. Calcular os novos atributos km de rede primária; potência instalada; número de unidades consumidoras; e consumo médio de cada conjunto;
4. Calcular através dos programas de análise de *clusters*, os novos agrupamentos. Neste caso, deverão resultar novos valores de metas de DEC, FEC, DIC e FIC para os novos conjuntos;
5. A partir dos valores de meta dos indicadores individuais e coletivos e seus valores históricos determinar os valores das metas para os anos 2004 a 2008 (anos posteriores à revisão tarifária);
6. Calcular as multas a serem pagas, nos anos de 2004 a 2008, para os agrupamentos com os seus respectivos históricos de interrupções para a nova configuração;
7. Comparar os valores da multa e escolher a melhor configuração;
8. Voltar ao passo dois até que o critério de otimização esteja satisfeito.

4.4 OTIMIZAÇÃO PARA AGRUPAMENTO

Para encontrar o melhor agrupamento de conjuntos, ou seja, a configuração onde o somatório das multas de todos os conjuntos seja a menor possível é preciso resolver um problema de agrupamento de áreas distintas. Considerando que se tenha apenas 2 municípios e cada um desses fosse dividido em urbano e rural, ter-se-ia 21 formas possíveis de combinar as áreas formando conjuntos, isto é, tomando os municípios 1 e 2 e dividindo-os em áreas urbanas e rurais de maneira que passamos a ter quatro áreas (A,B,C,D) podemos combinar essas áreas de diversas maneiras.

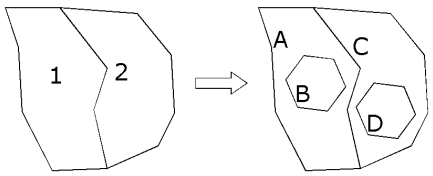

FIGURA 15 – Combinação de dois municípios – Área urbana e rural
Fonte: (STRAUCH, 2009)

Pode-se considerar todas as áreas juntas em um único conjunto, haverá apenas uma formação de conjunto possível =que será a soma de todas as áreas (ABCD).

$$C_4^4 = \frac{4!}{4!(0!)} = 1;$$

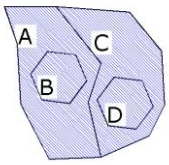

FIGURA 16 – Formação de um único conjunto
Fonte: (STRAUCH, 2009)

Pode-se considerar todas as áreas isoladas, cada uma como um conjunto; haverão quatro formações de conjuntos possíveis =(A), (B), (C), (D), conforme a figura 17.

$$C_1^4 = \frac{4!}{1!(4-1)!} = 4;$$

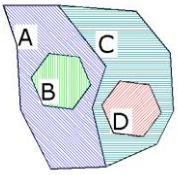

FIGURA 17 – Formação de quatro conjuntos
Fonte: (STRAUCH, 2009)

Pode-se fazer combinações de uma área isolada e três unidas. Neste caso tem-se as seguintes possibilidades: (A)(BCD); (B)(ACD); (C)(ABD); (D)(ABC) , conforme a figura 18.

$$C_1^4 \times C_3^3 = 4 \times 1 = 4;$$

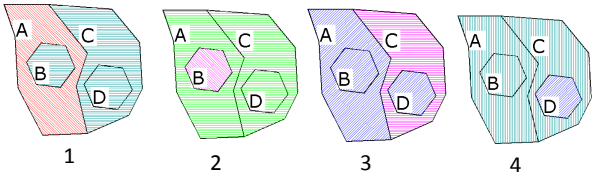

FIGURA 18 – Formação de conjuntos com áreas agrupadas três a três
Fonte: (STRAUCH, 2009)

Pode-se combinar as áreas agrupadas 2 a 2: (AB) (CD); (AC) (BD); (AD) (CB); (BC) (AD); (BD) (AC); (CD) (AB) , conforme a figura 19.

$$C_2^4 \times C_2^2 = 6 \times 1 = 6;$$

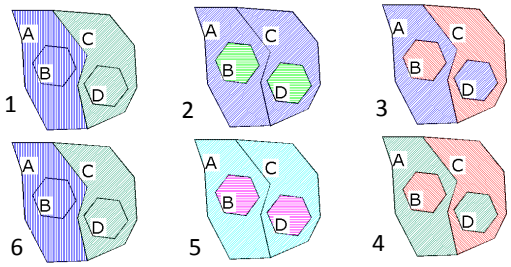

FIGURA 19 – Formação de conjuntos com áreas agrupadas dois a dois.
Fonte: (STRAUCH, 2009)

Note-se que dos 6 conjuntos possíveis, três são repetidos, 1=6, 2=5, 3=4.

Finalmente, Pode-se fazer combinações de áreas agrupadas 2, 1, 1: (AB) (C)(D); (AC) (B)(D); (AD) (C)(B); (BC) (A)(D); (BD) (A)(C); (CD) (A)(B) , conforme a figura 20.

$$C_2^4 \times C_1^2 \times C_1^1 = 6 \times 1 \times 1 = 6;$$

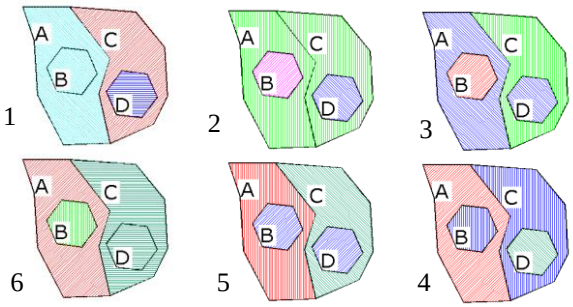

FIGURA 20 – Formação de conjuntos com áreas agrupadas dois, um,um.
Fonte: (STRAUCH, 2009)

Para 4 áreas, haverá 21 possibilidades de combinações, sendo que 3 delas são repetidas, o que nos deixa com 18 possibilidades.

Mesmo identificando as combinações não repetidas, nem todas as possibilidades são viáveis, pois uma das restrições impostas na Resolução 024/2000 é que as áreas dos conjuntos sejam contínuas, portanto não é possível, por exemplo: ter a solução formada por (BD)(A)(C), pois (BD) não pode formar um conjunto. Se expurgarmos todas as soluções que contém conjuntos que não podem ser combinados, passamos a ter 12 possibilidades [35].

A solução para verificar esta restrição é construir uma “matriz de adjacências” de maneira que as possibilidades de conjuntos geradas sejam analisadas nesta matriz,

[35] A solução para encontrar o número de agrupamentos de n áreas em conjuntos não vazios e sem repetição é dada pelo n-ésimo número de Bell, B(n). Esse número pode ser obtido do triangulo de Bell, no qual: B(1)=1; B(2)=2; B(3)=5; B(4)=15; B(5)=52. O número cresce exponencialmente, de maneira que B(20)=5.832.742.205.057, como temse 816 áreas, o processamento seria inviável. Claro que nem todos os arranjos terão apenas conjuntos adjacentes.

que possibilitará expurgar todas as possibilidades de combinação de áreas não vizinhas. Ou até mesmo de áreas vizinhas, mas que não devam ser agrupadas em um mesmo conjunto por restrições físicas ou administrativas. Sendo assim a “matriz de adjacências” acaba por evoluir para uma “matriz de restrição” que deve ser definida levando em consideração a geografia, o conhecimento da operação do sistema elétrico e outras restrições que sejam pertinentes. A seguir será apresentada a matriz de adjacências para o exemplo anterior:

	A	B	C	D
A	X	1	1	0
B		X	0	0
C			X	1
D				X

FIGURA 21 – Matriz de restrição
Fonte: (STRAUCH, 2009)

Na matriz os números “1” correspondem a combinações possíveis e os números “0” a áreas não contínuas e/ou restrições físicas, administrativas.

4.4.1 A escolha do Método de Otimização

A escolha do método de otimização é um fator decisivo no sucesso do processo de otimização. Inicialmente pensou-se na utilização do método *branch and bound*. A escolha de um modelo tipo *branch and bound* pressupõe uma regra para “podar” os ramos da árvore de desenvolvimento de soluções. No caso de um modelo de minimização de custos, qualquer ramo viável com custo superior à melhor solução já encontrada pode ser podado, porém no caso do Sistema de Otimização da Multa Global de Continuidade (SOA), apresentado no capítulo 05, a combinação de áreas não garante que o custo da multa seja progressivo (nem crescente, nem decrescente), portanto seria necessário encontrar outra função para poda que não a função custo a ser minimizada.

Isto é, supondo 5 conjuntos A, B, C, D, E, se os conjuntos A e B forem unidos, a meta para o novo conjunto será maior que as metas para os dois conjuntos

individuais, o que otimizaria a multa. Ao unirmos C aos dois conjuntos anteriores (ABC) a meta pode ficar menor do que a anterior, o que indicaria a poda deste ramo, porém é possível que ao unirmos o conjunto D (ABCD) a meta volte a crescer, de maneira que o ramo não deveria ser podado.

Por exemplo: se considerarmos alguns conjuntos de uma região metropolitana, (para simplificar será usada a comparação do DEC medido com o decil do *cluster* ao invés de com a meta). A comparação com o decil do *cluster* nos indica que se o DEC medido for inferior ao decil (diferença negativa) o conjunto não será objeto de multa, se o DEC medido for superior ao decil (diferença positiva) não significa que haverá multa, pois a meta do conjunto pode estar acima do DEC medido, mas para simplificação da análise admite-se que o conjunto será multado. Portanto, para análise a seguir, o objetivo será tornar a diferença o mais negativa possível.

Tabela 07 - Dados de Conjuntos

CONJUNTOS	DEC MEDIDO 2001	CLUSTER ATUAL	DECIL DO CLUSTER	DEC - DECIL
Conjunto I	17,95	26	14,69	3,26
Conjunto II	22,38	22	20,71	1,67
Conjunto III	25,84	22	20,71	5,13
Conjunto IV	17,75	22	20,71	-2,96
Conjunto V	22,2	4	29,36	-7,16
Conjunto VI	16,36	27	26,73	-10,37
Conjunto VII	16,69	17	22,16	-5,47
Conjunto VIII	32,76	17	22,16	10,6
Conjunto IX	19,52	22	20,71	-1,19

Fonte: (STRAUCH, 2009)

Supondo que combine-se os conjuntos II e III (Tabela 08), o *cluster* do novo conjunto será o vinte e dois (22) e a diferença para o decil será de 3,15, situação melhor que a anterior (1,67+5,13=6,80)

Tabela 08- Dados de Conjuntos combinados 1.

CONJUNTOS	DEC MEDIDO 2001	CLUSTER ATUAL	DECIL DO CLUSTER	DEC- DECIL
Conjunto II + Conjunto III	23,86	22	20,71	3,15

Fonte: Fonte: (STRAUCH, 2009)

Combinando o conjunto I com os dois anteriores (Tabela 09), o novo cluster será o 26 e a diferença para o decil será de 8,63, piorando a situação anterior, (8,63>3,15)[36].

Tabela 09- Dados de Conjuntos combinados -2.

CONJUNTOS	DEC MEDIDO 2001	CLUSTER ATUAL	DECIL DO CLUSTER	DEC- DECIL
Conjunto I + Conjunto II + Conjunto III	23,32	26	14,69	8,63

Fonte: Fonte: (STRAUCH, 2009)

Essa situação inviabiliza o uso de um algoritmo do tipo *branch and bound*. Além disso, independente do objetivo a ser alcançado (zerar multa ou torná-la o mais "negativa" possível), o problema em questão é um problema de explosão combinatória. O universo da concessionária em estudo é formado por 418 conjuntos, que devem ser subdivididos em, aproximadamente 816 áreas. Parece obvio que não será possível verificar exaustivamente todas as possibilidades de combinação, expurgar as repetidas e as impossíveis e calcular as multas para todas as possibilidades de combinação restantes.

Inicialmente, optou-se por usar algoritmos genéticos para otimizar o processo de recombinação de áreas; a seguir será descrita a modelagem inicial do problema.

4.4.2 Modelagem do Problema por AG

A otimização proposta, é a maximização da diferença entre meta de DEC de cada conjunto e seu DEC real, de maneira que os conjuntos estejam o mais distantes das metas de DEC e, portanto, mais distantes da necessidade de investimento para incrementar os índices de qualidade.

$$Max \quad \sum_{i-1}^{n} MetaDEC_i - DEC_{ri} \tag{24}$$

Onde:

n é o número de conjuntos da solução proposta,

[36] Apesar da última configuração ser "pior" que a anterior, provavelmente as duas tenderiam a zerar a

$MetaDECi$ é a meta do DEC para o conjunto i

DEC_{ri} é o DEC real ou medido do conjunto i.

As restrições do problema são:

- O número de conjuntos a serem formados :

  $i \leq K \quad \therefore \quad K \text{ é definido pelo usuário}$

- A área máxima de cada conjunto

  $Área_j \leq K_1 \quad \therefore \quad K_1 \text{ é definido pelo usuário}$

- O número máximo de consumidores em cada conjunto

  $NumCons_j \leq K_2 \quad \therefore \quad K_2 \text{ é definido pelo usuário}$

- A continuidade entre as áreas agregadas
- A não repetição de uma área em mais de um conjunto.

Outra restrição foi implementada para diminuir o tempo de resposta do algoritmo de otimização: a área mínima utilizada será a unidade municipal.

4.4.2.1 Codificação do indivíduo

Supondo uma regional com n municípios, a solução será representada por um indivíduo com n cromossomos, onde cada cromossomo corresponde à posição de um município da regional (Figura 22).

Posição	1	2	3	...	n-2	n-1	n
Cromossomo	x	x	x	x	x	x	x

Figura 22 – Modelagem inicial do individuo

Cada cromossomo do indivíduo poderá conter números entre 1 e n, de maneira que cada conjunto será formado por todos os municípios com mesmo números . Por exemplo, considerando uma regional A, formada pelos municípios a, b, c, d, e, f, g e h (Figura 23), respectivamente colocados nas posições 1, 2, 3, 4, 5, 6, 7 e 8 do cromossomo.

---

multa de DEC, pelo menos nos primeiros anos, o que mantém a pergunta: Que é otimização do SOA?

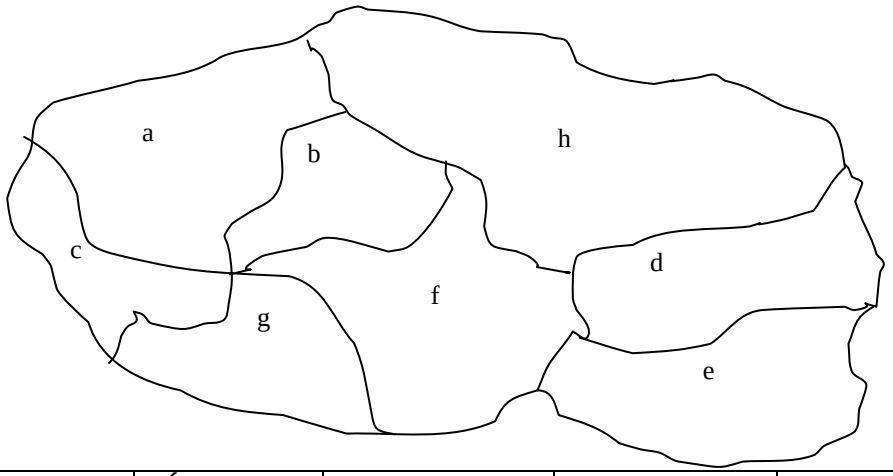

MUNICÍPIO	ÁREA (KM²)	Nº CONS	META DE DEC	DEC REAL
a	30	340	38	45
b	25	387	23	20
c	20	235	42	45
d	28	284	31	20
e	32	842	24	28
f	45	947	31	20
g	26	763	23	24
h	48	983	32	20

Figura .23- Regional fictícia e dados
Fonte: Strauch 2005

A solução atual será aquela formada por cada conjunto igual a cada município, isto é, o indivíduo correspondente aos conjuntos (a), (b), (c), (d), (e), (f), (g) e (h) apresentado na figura 24:

1	2	3	4	5	6	7	8

Figura 24 – Individuo atual

Para gerar o individuo (Figura 25), sorteiam-se números de 1 a 8 para cada cromossomo e números iguais corresponderão a conjuntos iguais, de maneira que o indivíduo corresponde à solução formada por 5 conjuntos a saber, (a+b), (c+d),(e+h),(f),(g).

3	3	5	5	7	1	6	7

Figura 25 – Individuo formado pela união das áreas (a+b), (c+d),(e+h),(f),(g).

O indivíduo corresponde à solução formada por 5 conjuntos a saber, (a+f),(b),(c), (d+e+g),(h) (Figura 26).

8	6	2	3	3	8	3	1

Figura 26 – Individuo formado pela união das áreas (a+f),(b),(c), (d+e+g),(h).

O indivíduo corresponde à solução formada por 4 conjuntos a saber, (a), (b+d+g),(c+f),(e+h) (Figura 27).

2	4	7	4	3	7	4	3

Figura 27 – Individuo formado pela união das áreas (a), (b+d+g),(c+f),(e+h).

O indivíduo corresponde à solução formada por 5 conjuntos a saber, (a), (b),(c+d+e+f),(g),(h) (Figura 28).

7	2	1	1	1	1	6	4

Figura 28 – Individuo formado pela união das áreas (a+b), (c+d),(e+h),(f),(g).

4.4.2.2 População Inicial

Em função do número de combinações possíveis de formação de número de conjuntos procurou-se a teoria da amostragem para determinar o número de indivíduos na população inicial, em Spiegel (1993) encontra-se:

$$n = \frac{N \times n_o}{N + n_o} \tag{25}$$

Onde ;

n = Tamanho da amostra

N = Tamanho da população (número de conjuntos possíveis)

$n_o = \frac{1}{\varepsilon^2}$ = Inverso do erro admissível.

Como o número de conjuntos possíveis é muito grande o tamanho da amostra converge para uma população inicial de 400 conjuntos. Isto deve garantir que a população represente o espaço de soluções do problema. Evidente que as 400 soluções não precisam estar na população inicial.

Várias formulações foram feitas para determinação da população inicial. Segundo Lobo e Lima (2005), o número de indivíduos mais usado vária entre 30 e 50. Finalmente, o tamanho da população inicial será definido para cada simulação e o desempenho do algoritmo vai ser analisado em função deste valor.

4.4.2.3 Função de avaliação

Um importante item relacionado com o sucesso do algoritmo genético é a escolha da função de avaliação das gerações de indivíduos. Dado um cromossomo, a função de avaliação deve retornar um número que representa sua aptidão (*fitness*) que é proporcional à qualidade da solução representada por aquele cromossomo. A função de avaliação deve determinar a probabilidade que o cromossomo tem de continuar sua evolução para as próximas gerações.

Para o caso em questão, a função de avaliação será composta por cinco parcelas, a saber:

- valores de DEC reais; terá peso relativo a k da função de avaliação, sendo que 0 ≤ k≤1;
- a segunda parcela terá peso relativo a (1 - k) da função de avaliação. Sendo que a segunda parcela é composta dos seguintes subitens, que verificará as restrições;
    - A continuidade dos conjuntos gerados;
    - O número de consumidores em cada conjunto;
    - A área de cada conjunto;
    - O número de conjuntos por regional.

$$Função\ Avaliação = k \times \sum_{i=1}^{n} (MetaDEC_i - DEC_i)_i + (1-k) \times \sum_{i=1}^{n} (MetaDEC_i - DEC_i)_i \times \left\{ \left[\frac{\sum_{i=1}^{n}(a_i)}{n1}\right] + \left[\frac{\sum_{i=1}^{n}(b_i)}{n1}\right] + \left[\frac{\sum_{i=1}^{n}(c_i)}{n1}\right] + \left[\frac{\sum_{i=1}^{n}(d_i)}{n1}\right] \right\} \quad (26)$$

Onde;

n = número de conjuntos gerados em cada solução;

a_i = 1, se o conjunto for contíguo; e 0, se o conjunto i não for contínuo;

b_i = 1, se o conjunto i tiver número de consumidores entre o máximo e mínimo estabelecidos, e 0, se o conjunto i tiver menos ou mais consumidores que o máximo e mínimo estabelecidos;

c_i = 1, se o conjunto tiver área menor que o valor máximo estabelecido, e 0,se o conjunto i tiver área maior que o valor estabelecido;

d_i = 1, se n for menor que o número de conjuntos máximo estabelecido, e 0, se n for maior que o número de conjuntos máximo estabelecido.

No software desenvolvido, o parâmetro K foi colocado de forma explicita, podendo realizar as simulações com pequenas derivações da função avaliação. Os valores de K devem ser elevados, já que a função objetivo deve ser mais influente que as restrições, dado que estas não são impositivas.

Na prática a função avaliação pode se tornar negativa, o que determinou modificação para torná-la positiva, de modo a que fosse possível utilizar-se da roleta. Assim, para cada indivíduo de cada geração, somou-se o valor o menor valor + 1 da valor da função avaliação de cada indivíduo. Este passo não influenciou ou modificou o valor relativo das probabilidades dos indivíduos, já que na normalização das probabilidades os valores relativos estavam preservados.

Após algumas simulações observou-se fenômeno similar ao apresentado nos textos sobre o assunto: a convergência prematura com a utilização da função avaliação. Neste caso, optou-se pela linearização da função avaliação conforme apresentado em Kagan e Bento (2009). Para finalizar o processo de avaliação dos indivíduos, os valores foram normalizados, podendo-se passar para o próximo passo do Algoritmo Genético.

4.4.2.4 Métodos de seleção

Neste ponto existe a necessidade de realizar a seleção dos indivíduos que participaram da determinação da próxima geração. Vários métodos de seleção foram implementados no modelo de Algoritmos Genéticos:

1. Elitismo pode aumentar rapidamente o desempenho do AG, porque previne a perda da melhor solução já encontrada. Conceito semelhante ao Elitismo é o

Intervalo de Geração, só que neste caso um percentual do melhores indivíduos são preservados. No modelo de seleção implementado, os melhores indivíduos podem ser passados para a próxima geração sem sofrer nenhuma alteração. O valor percentual foi definido como parâmetro de entrada do software e pode variar, conforme conveniência do analista. Outra opção implementada no software foi a possibilidade desses melhores indivíduos participarem ou não da recombinação dos indivíduos, o que permitiu grandes diferenças de desempenho que serão apresentadas no capítulo seguinte.

2. Seleção por Roleta – na implementação pode-se usar a combinação do Elitismo e da Seleção por Roleta;

3. Seleção por Torneio - procurou-se também analisar o desempenho do algoritmo, caso fosse utilizado o Torneio como método de seleção. Foram dadas opções para o número de indíviduos que participam do torneio,

4. Seleção por *ranking* – A simulação por ranking é aponta da em Kagan et al (2008), entre as melhores métodos de seleção nos AG, desta forma foi inclída a possibilidade de utilização deste método de seleção.

Assim, colocou-se como parâmetro de entrada da simulação de otimização a possibilidade de escolha entre os métodos de Roleta, Torneio e ranking.

4.4.2.5 Cruzamento, mutação e critério de parada

Os operadores mais utilizados para reprodução são o cruzamento (*crossing-over*) e a mutação, já descritos. Para o problema em questão utilizou-se o cruzamento em n pontos, onde n será definido aleatoriamente em cada cruzamento (objetiva-se com isso diversificar ao máximo a população). Este parâmetro foi colocado como parâmetro inicial da simulação do software.

Ainda quanto ao cruzamento foi dada a opção de que apenas parte dos cruzamentos fossem efetivados, o intervalo de cruzamento é um dado de entrada da otimização. Também, foi implementado como parâmetro de entrada da otimização o percentual da mutação que vai incidir sobre a população, de forma a identificar o efeito deste operador sobre o desempenho da otimização. Não foi implementada o cruzamento contínuo, pois este tipo de cruzamento determinaria uma nova geração totalmente diferente dos seus pais.

Após algumas gerações o algoritmo deve parar e oferecer a solução encontrada. Geralmente para o mecanismo de parada aplicam-se critérios de tempo, número de gerações ou de avaliação do resultado como mecanismos de parada do algoritmo genético.

Como o algoritmo em questão é não convergente, a definição da avaliação do resultado não pode ser utilizada, por isso o critério de parada será o número de gerações. No software o número de gerações pode ser definido para cada simulação.

4.4.2.6 Problemas encontrados

Ao testar o módulo de geração da população inicial, notou-se que o número de soluções não válidas era muito grande. A geração aleatória fez com que, várias vezes, a população inicial não tivesse nenhum indivíduo válido, isto é, nenhuma solução gerada era composta apenas por áreas contínuas. Como o mesmo problema podia se repetir no cruzamento, uma vez que a combinação de dois indivíduos gera conjuntos inválidos, foi preciso encontrar outra solução para a criação dos indivíduos.

A dificuldade de criar uma população inicial e depois garantir indivíduos válidos na geração seguinte, suscitou a necessidade de utilização de outra ferramenta de otimização. Duas soluções foram estudadas: (1) uma previa que um primeiro indivíduo fosse resultado do agrupamento de uma grande área, enfim vários

municípios, e que essa área fosse sendo dividida para gerar subconjuntos válidos e dessa maneira gerar os diversos indivíduos ou (2) que a geração de indivíduos válidos partisse da área totalmente separada onde fossem sendo agregadas partes da área para gerar indivíduos válidos.

4.4.3 Algoritmos imunológicos modificados

Para resolver este problema, a população foi gerada através de um modelo criado misturando técnicas de algoritmos imunológicos (seleção clonal) e genéticos (mutação), ao qual se denominou Algoritmos imunológicos modificados. A utilização dos SIA não foi uma alternativa pensada a priori, e sim uma tentativa de resolver o problema, já que com a utilização dos Algoritmos Genéticos não foi possível.

Duas soluções foram estudadas: a primeira previa que a regional fosse agrupada em uma grande área e que essa área fosse sendo dividida para gerar subconjuntos válidos e dessa maneira gerar os diversos indivíduos ou que a geração de indivíduos válidos partisse da área totalmente separada onde fossem sendo agregadas partes da área para gerar indivíduos válidos. Para resolver este problema, a população foi gerada através de um modelo criado misturando técnicas de algoritmos imunológicos. A solução implementada é descrita a seguir.

O indivíduo 1 é formado pela solução inicial, ou seja, cada conjunto é um município. (ex: 16 conjuntos da região Metropolitana de Salvador). O indivíduo 2 é formado da seguinte forma:

1. Faz-se um clone do indivíduo 1, sorteia-se um conjunto deste clone (exemplo: Cachoeira) e sorteia-se um outro conjunto na lista de adjacência desse município, unindo-os (ex: São Felix).
2. O indivíduo 2 é então um clone do indivíduo 1 que sofreu uma mutação, sendo formado por um conjunto de dois municípios e o resto dos conjuntos

são os municípios sozinhos. (ex: 15 conjuntos para região Metropolitana de Salvador).

O indivíduo 3 é formado da seguinte forma:

1. Sorteia-se um dos indivíduos existentes para ser clonado .
2. Sorteia-se um conjunto deste indivíduo clonado, e sorteia-se outro conjunto na lista de adjacência desse(s) município(s) para ser agregado ao conjunto (mutação).
3. O indivíduo 3 é formado por um ou dois conjuntos e o resto dos conjuntos serão municípios sozinhos.

Assim sucessivamente até formar os indivíduos necessários para a população inicial. Se um dos municípios sorteados na lista de adjacências já fizer parte de um conjunto, esse conjunto inteiro é agregado ao conjunto que está sendo formado.

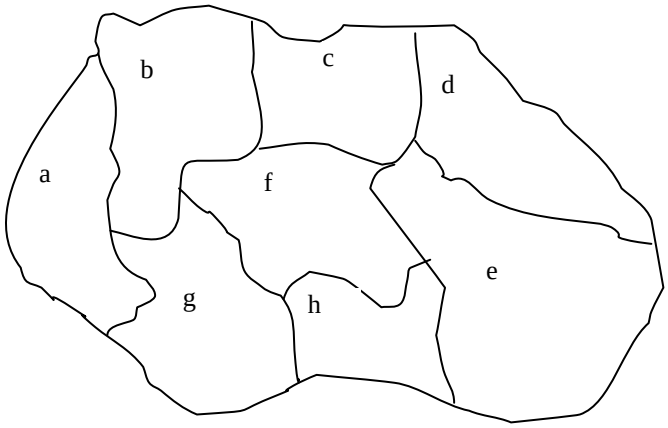

Figura 29. Exemplo de Regional fictícia
Fonte: Elaboração própria

1. Individuo 1: (solução inicial): a,b,c,d,e,f,g,h;
2. Individuo 2: Clona o indivíduo 1 e sorteia-se um conjunto (c), sorteia-se outro na lista de adjacências deste (f) e une o c e o f: cf, a,b,d,e,g,h;
3. Indivíduo 3: Clona um dos dois indivíduos anteriores, supondo sorteio do indivíduo 2 e sorteia-se um conjunto (g), sorteia-se outro na lista de adjacências deste (a), une os dois: cf,ag,b,d,e,h;
4. Indivíduo 4: Clona um dos indivíduos anteriores, supondo sorteio do indivíduo 2 e sorteia-se um conjunto (cf), sorteia-se outro na lista de adjacências deste (e), une os sorteados: cfe,a,b,d,g,h;

5. Indivíduo 5: Clona um dos indivíduos anteriores, supondo o indivíduo 3 e sorteia-se um conjunto (h), sorteia-se outro na lista de adjacências deste (f) que está em outro conjunto (cf): hcf, ag, b, d, e, E assim sucessivamente.

Apesar de melhorar o desempenho do software, a introdução do algoritmo imunológico modificado não foi suficiente torná-lo aceitável, pois, para gerar uma população inicial criou-se uma população viesada sem a certeza de que a heurística utilizada encaminhasse para uma solução ótima global.

4.6 NOVA MODELAGEM PARA O PROBLEMA

Uma nova modelagem foi proposta para o problema. Supondo uma regional com n municípios, apresentado na figura 30, o indivíduo será representado por n cromossomos, onde cada cromossomo corresponde à ligação existente entre os conjuntos de consumidores. Se o gene for 0 significa que os conjuntos não estão unidos, o inverso ocorre se o gene tiver o número 1. O indivíduo apresentado na figura 30 tem a seguinte modelagem:

a - b	a - c	a - h	b - f	b - h	b - g	c - g	d - e	d - f	d - h	e - f	f - h	f - g

Figura 30 – Modelo do novo indivíduo

O indivíduo corresponde à solução formada por 5 conjuntos a saber: (a+b), (c+g),(d+e),(h),(f),(g), é apresentado na Figura 31.

1	0	0	0	0	0	1	1	0	0	0	0	0

Figura 31 – Individuo (a + b), (c + g), (d + e), (h), (f), (g)

Nesta modelagem, todos os indivíduos criados são válidos, ou seja as áreas são contíguas. Com as modificações realizadas o Algoritmo Genético e Imunológico funcionou, possibilitando a determinação de configurações de conjuntos de consumidores adequadas.

4.7 ALGORITMOS IMUNOLÓGICOS

Alguns parâmetros utilizados nos Algoritmos Genéticos são os mesmos na utilização de Algoritmos de Seleção Clonal:

- População Inicial;
- Função Avaliação:
    - Mudança na função objetivo;
    - Linearizada;
- Número de Gerações.

As diferenças de implementação ocorreram nos métodos de geração das novas soluções/indivíduos. No Algoritmo de Seleção Clonal a nova geração é realizada através da clonagem ou hipermutação somática. Na implementação, todos os indivíduos geram clones, cujo valor pré-definido é 10 e cada clone pode ter uma mutação máxima de 20% do indivíduo original.

Duas formas de seleção dos indivíduos foram utilizadas. Na primeira, é escolhido o melhor clone dos dez gerados para cada indivíduo, neste caso apenas um deles sobrevive para a próxima geração. Na segunda, todos os indivíduos são avaliados e os melhores de todos os clones são escolhidos.

Antes da definição da população da próxima geração pode haver necessidade de implementar a supressão de indivíduos com grande afinidade. Isto deve ocorrer segundo uma taxa que é o limiar de similaridade, que é parametrizável. Assim indivíduos muito próximos deverão ser suprimidos da população, imprimindo uma diversificação na população dos indivíduos. Este processo deve ocorrer a cada 5 gerações.

Esta implementação do Algoritmo de Seleção Clonal simplificada em relação as possibilidades do Algoritmo Genético irá se refletir nos resultados obtidos. Ainda assim, permite um bom desempenho comparado, como será demonstrado no próximo capítulo.

4.8 CONCLUSÃO DO CAPÍTULO

Conforme apresentado, o problema desta Tese é semelhante ao de redistribuição de eleitores nos distritos de votação nos EUA, conhecido como Political Districting, ou School Redistriting,

Inicialmente previa-se a utilização de técnicas de otimização baseada em Programação Matemática para tratar da minimização da multa global de continuidade para uma concessionária. Entretanto, à medida que o estudo foi desenvolvendo, verificou-se a impossibilidade de utilização da técnica de Programação Inteira *Branch and Bound*.

A solução estudada em seguida foi o desenvolvimento de um modelo de otimização baseado em Algoritmos Genéticos que é capaz de encontrar uma solução que minimiza a multa global de continuidade, mesmo que não encontre o valor ótimo, já que os algoritmos evolutivos não garantem o ótimo.

A modelagem inicial dos indivíduos trouxe uma dificuldade intransponível para otimização via Algoritmos Genéticos. A alternativa foi incluir os estudos de Sistemas Imunológicos Artificiais, especificamente o Algoritmo de Seleção Clonal, pela maior facilidade na criação dos indivíduos. O modelo desenvolvido resolveu o problema, mas apresentava-se como uma solução viesada, já que a base conceitual dos Algoritmos Evolutivos é a utilização do sorteio aleatório.

A construção de um outro tipo de indíviduo permitiu a utilização dos modelos clássicos de AG e o ASC. O modelo desenvolvido é capaz de combinar os conjuntos, encontrando soluções que respeitam as restrições escolhidas e simulam as multas de continuidade para o(s) ano(s) escolhido(s), dando ao operador um panorama da situação caso altere seus conjuntos de consumidores, tanto através de Algoritmos Genéticos quanto pelo Algoritmo de Seleção Clonal. No próximo capitulo serão analisados os resultados das simulações.

5 APLICAÇÃO DA METODOLOGIA

Após a análise dos conjuntos de consumidores, partiu-se para aplicar a metodologia de redistribuição dos conjuntos de consumidores. Evidentemente, a manipulação e reagrupamento dos consumidores não poderia ser realizada sem a utilização de software gráfico.

O software desenvolvido foi denominado de Sistema de Otimização da Multa Global de Continuidade (SOA). O software apresenta uma interface gráfica extremamente interativa. A tela principal, Figura 32, apresenta o mapa do estado da Bahia (área de concessão da COELBA), dividido em unidades regionais de gestão e subdividido na menor unidade territorial para a qual a concessionária teve capacidade de disponibilizar os indicadores dos conjuntos solicitados pela ANEEL (subdivisão dos municípios em conjuntos de unidades consumidoras (CUC) urbanos e não urbanos).

O SOA permite que o usuário crie diversas simulações de agrupamentos entre as localidades da área de concessão, possibilitando a análise da incidência de multa para as combinações geradas. O usuário pode fazer isso de forma interativa, agregando e desagregando localidades uma a uma manualmente e/ou de forma automática, através da execução do algoritmo de otimização que produz uma solução ótima para uma regional combinando diversas localidades da mesma.

Para facilitar a visualização das informações e a análise dos resultados obtidos com as combinações, o SOA disponibiliza o mapa da Bahia apresentando as localidades da área de concessão com uma coloração que vai do vermelho intenso ao azul intenso passando pelo branco, de acordo com o risco regulatório de cada localidade.

Além disso, o SOA oferece outras funcionalidades para a importação de dados, para a emissão de relatórios e para a configuração do sistema, necessárias tanto para validar as agregações feitas como para o cálculo da multa de uma simulação. Após abrir a simulação escolhida, ou criar uma nova simulação, a tela principal do SOA, com o mapa do estado, estará disponível.

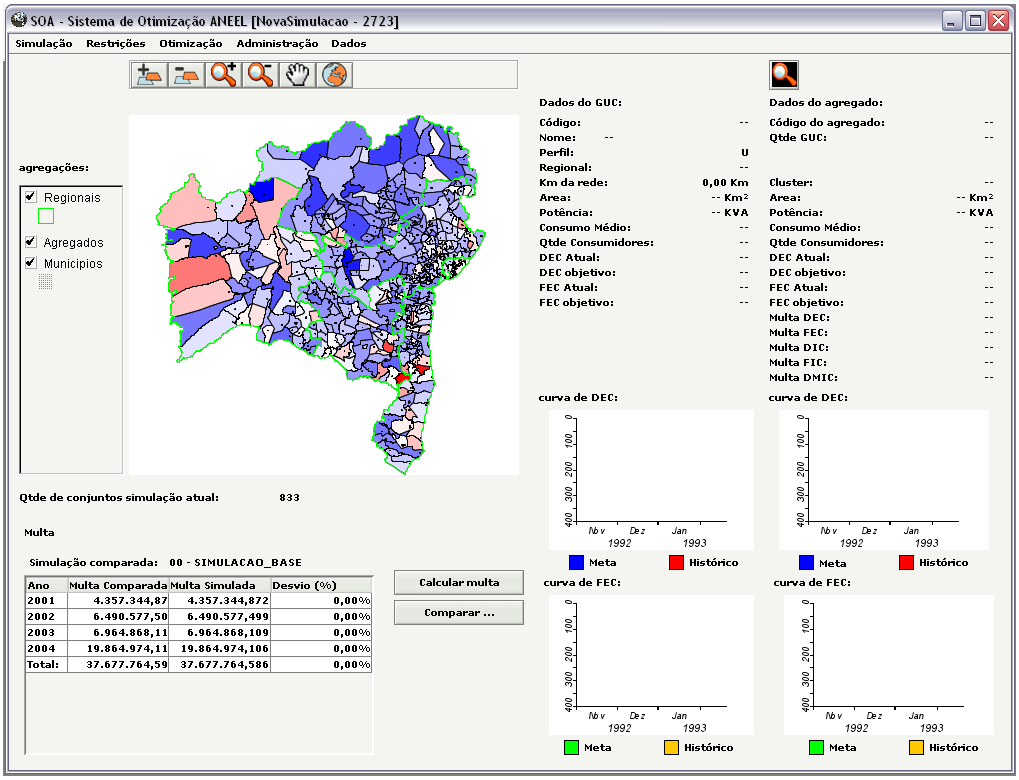

Figura 32. Tela Principal do SOA

Nesta tela o operador pode identificar pela cor quais os conjuntos que estão mais distantes de atingir as metas de DEC (quanto mais vermelho, mais acima da meta está o valor medido do DEC, quanto mais azul, mais abaixo da meta está o valor medido do DEC).

5.1 REDISTRIBUIÇÃO DOS CONJUNTOS DE CONSUMIDORES EM NOVOS CLUSTERS ATRAVÉS DE ALGORIMOS GENÉTICOS.

Várias simulações foram feitas com a finalidade de testar os diversos parâmetros de entrada dos Algoritmos Genéticos. A figura 33 apresenta a tela do SOA em que apresentam-se as variáveis que podem ser modificadas pelo usuário:

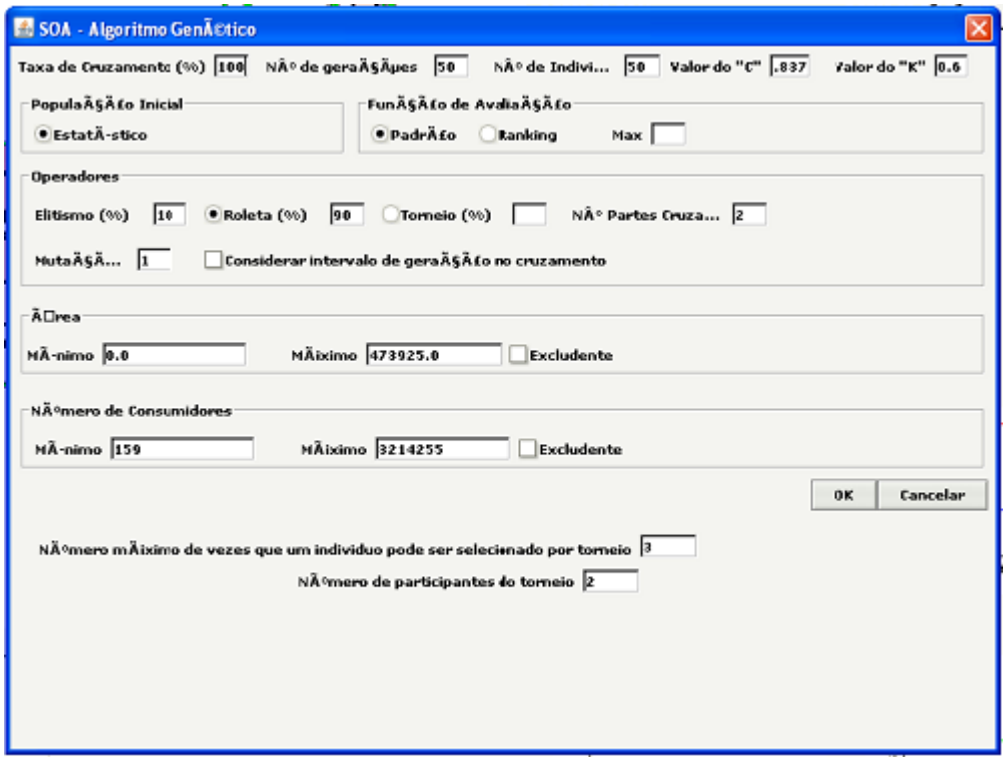

Figura 33 – Parâmetros de entrada dos Algoritmos Genéticos

Para simulações da otimização, foram inicialmente escolhidos os valores dos parâmetros para simulação, que constam na tabela 10. Estes valores tem fundamentação nas diversas referências estudadas. Entretanto, precisou-se analisar o comportamento destas variáveis, no problema em estudo, para determinar os valores que seriam utilizados.

Tabela 10: Valores dos parâmetros inicialmente analisadas para o AG

Parametros	Valores	
	Mínimo	**Máximo**
População Inicial	**30**	**80**
Função Avaliação		
Mudança da função objetivo	**0,6**	**0,8**
Linearização da função avaliação	**0,6**	**0,8**
Metodo de Seleção		
Elitismo	**1%**	**10%**
Roleta		
Torneio	**2**	**4**
ranking	**1,3**	**1,5**
Cruzamento		
(2 a 10 pontos)	**2pto**	**10ptos**
Intervalo de cruzamento	**0,8**	**1**
Mutação	**1%**	**10%**
Número de Gerações	**30**	**100**

A seguir é apresentada a análise dos diversos parâmetros.

5.1.1 Análise inicial dos Parâmetros

No primeiro teste, o objetivo foi analisar a formação da população inicial. O receio era que uma população inicial pequena não refletisse o espaço de soluções. Desta forma foram analisados três possibilidades de populações iniciais (30, 50 e 80 indivíduos), mantendo-se os outros parâmetros, e comparando os resultados com o valor da configuração atual.

Analisando os resultados, verificou-se que os valores de avaliação dos indivíduos foi muito baixo, inferior ao valor da configuração atual, mesmo com uma população inicial com 80 indivíduos. Após várias tentativas, observou-se que a taxa de conectividade deveria ser modificada para melhorar o desempenho da população inicial ou ainda ampliar a abrangência destas no espaço de soluções. A figura 34 deve melhorar o entendimento.

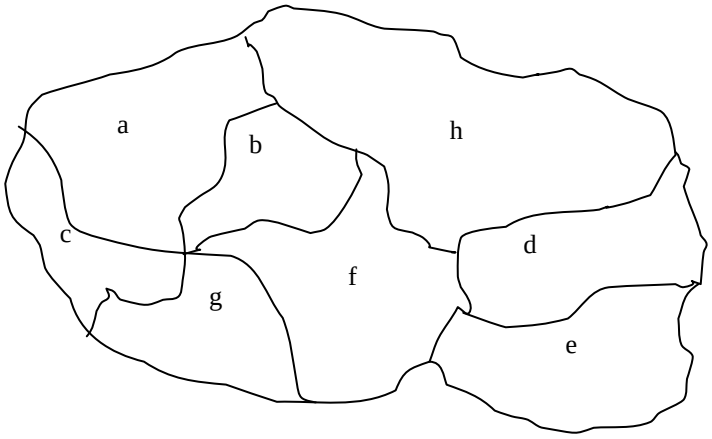

Figura 34. Exemplo de conjuntos fictícios

O conjunto de soluções possíveis e/ou indivíduos do conjunto de áreas pode ser expresso pelo vetor de ligações da Figura 35:

a - b	a - c	a - h	b - f	b - h	b - g	c - g	d - e	d - f	d - h	e - f	f - h	f - g

Figura 35 – Modelo do novo indivíduo

Para que todas as áreas pertençam ao mesmo conjunto, todos os valores devem ser 1, conforme figura 36:

1	1	1	1	1	1	1	1	1	1	1	1	1

Figura 36. Exemplo de Indivíduo do novo modelo

Porém, com um número bastante menor de ligações válidas, consegue-se o mesmo resultado, ou seja, todas as áreas estão em um único conjunto, apresentado na Figura 37.

1	0	0	1	1	1	1	0	1	0	1	0	0

Figura 37: Outro exemplo de Indivíduo do novo modelo

Para diversificar a formação dos indivíduos e cobrir o espaço de soluções é necessário reduzir o número de ligações válidas, diminuindo o número de valores iguais a um, nos indivíduos. A solução encontrada foi criar sorteios viesados, onde a probabilidade de sorteios de “zero” e “um” não são mais iguais. Assim, os indivíduos criados tem as seguintes probabilidades de sorteio:

- Para 10% dos indivíduos a probabilidade de número uns é de 90%, gerando poucos conjuntos, bastante agrupados
- Para 15% dos indivíduos a probabilidade de número 1 é de 70%;
- Para 50% dos indivíduos a probabilidade de número 1 é de 50%;
- Para 15% dos indivíduos a probabilidade de número 1 é de 30%;
- E os 10% restantes, terão uma probabilidade de 90% de valores zero.

Evidentemente, estes valores são empíricos e podem ser mudados, mas depois de diversas simulações estes valores foram os que apresentaram melhores avaliações para as populações iniciais.

A função avaliação influencia de forma decisiva no desempenho dos AG. Entretanto, com a função utilizada, a mudança possível era penalizar mais ou menos um indivíduo através da mudança de constante K. Esta variação não se mostrou suficiente para apresentar resultados diferentes nas diversas simulações. É bom lembrar que as restrições inseridas não são excludentes, são apenas orientativas, o que permite uma certa flexibilidade na utilização do parametro K.

Na comparação dos resultados não observou-se qualquer diferença visível que demonstrasse a necessidade de variação neste parâmetro. Os valores adotados na simulação (0,6 e 0,8) mostraram-se adequados para utilização na comparação. Isto deve-se ao fato de que a linearização já determina uma igualdade nas probabilidades dos diversos indivíduos

A simulação sem a utilização do elitismo resultou na perda dos melhores indivíduos, resultando em variações grandes de valores dos melhores indivíduos e/ou soluções, por outro lado a utilização de valores elevados, em torno de 10%, determina uma convergência à valores muito baixos, sem melhoria da melhor solução nem da média da população. Verificou-se que a utilização do elitismo melhora o desempenho do Algoritmo Genético, dos valores utilizados, a taxa de 3% apresentou-se mais promissora.

A seleção através da roleta apresentou-se muito convergente, em poucas gerações, os valores médios de avaliação dos indivíduos tornam-se muito próximos da melhor solução. Optou-se pela utilização de um novo parâmetro no software que determina o número máximo de vezes que um indivíduo poderia participar na formação da nova geração.

Na seleção por torneio simulou-se diversos padrões: 2, 4 e 8 indivíduos. Observou-se uma convergência muito rápida na utilização de 4 e 8 indivíduos, por torneio. Os indivíduos mais bem avaliados eram sempre vencedores do torneio, tornando a geração seguinte precocemente pouco diversificada. Novamente, optou-se pela utilização do torneio com dois indivíduos acrescentando também, o novo parâmetro no software que determinava o número máximo de vezes que um indivíduo poderia participar na formação da nova geração. Este valor foi fixado em 3, nas diversas simulações.

A seleção através do ranking mostrou uma convergência mais lenta do que os outros métodos de seleção, entretanto o desempenho apresentou-se comparável aos outros métodos.

Na comparação entre o número de cruzamentos foi utilizada a divisão do indivíduo em duas e dez partes. Não foi implementado o cruzamento contínuo, que aparece frequentemente na literatura. Esta decisão, conforme já apresentado, deve-se ao fato de que a nova geração seria completamente diferente de seus pais, o que poderia determinar uma não convergência do algoritmo.

O intervalo de cruzamento determina a taxa de cruzamentos que efetivamente ocorreram, simula uma taxa de sucesso para o cruzamento. Com as diversas

simulações realizadas a mudança do valor entre 0,8 e 1 não apresentou nenhuma diferença visível nos resultados, adotou-se para todas as simulações uma taxa de 0,85.

O número de gerações escolhido nesta etapa deveria ser grande o suficiente para evidenciar o desempenho das simulações com os parâmetros escolhidos, mas pequeno suficiente para não sobrecarregar as análises iniciais. O valor escolhido foi de 30 gerações.

5.1.2 Melhor combinação entre os parâmetros

As análises obtidas permitiram direcionar as novas simulações de forma a melhorar o desempenho dos Algoritmos Genéticos. Alguns parâmetros inicialmente explicitados não determinaram diferentes comportamentos nas diversas simulações, logo estes foram mantidos constantes para todas as simulações e são apresentados na Tabela 11.

Tabela 11: Parâmetros mantidos constantes para todas as simulações do AG

Parâmetros	Valores
População Inicial	50
Função Avaliação	
Mudança da função objetivo	0,8
Linearização da função	0,6
Método de Seleção	
Elitismo	3%
Cruzamento	
Intervalo de cruzamento	0,85
Número de Gerações	30

Outros parâmetros determinaram resultados suficientemente diferentes e foram explicitados para as diversas simulações, estes parâmetros são apresentados na Tabela 12.

Tabela 12: Valores dos parâmetros analisadas do AG

Parâmetros	Valores	
	Mínimo	Máximo
Método de Seleção		
Roleta		
Torneio	2	4
Ranking	1,3	1,5
Cruzamento		
(2 a 10 pontos)	2	10
Mutação	5%	10%

Para avaliação do desempenho dos diferentes parâmetros e depois compará-los foram realizadas 05 simulações, para cada uma das 20 possibilidades. Os resultados das simulações são apresentados no Anexo I deste trabalho. No Gráfico 07 é apresentado o resultado do primeiro tipo de simulação do AG:

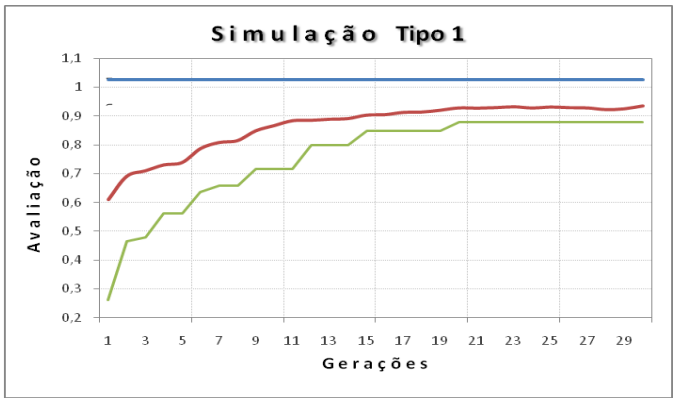

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Roleta	
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 07: Desempenho do AG na simulação do tipo 1

A seguir é apresentada a análise de cada parâmetro, a partir das simulações realizadas:

- Método de Seleção – Nas simulações realizadas determinou uma pequena diferença entre a seleção pelos métodos de Roleta,Torneio e ranking. Aparentemente, a convergência dos resultados é maior na seleção através do Torneio, e roleta, apresentando-se menor no ranking. Decidiu-se simular os métodos com mais gerações para poder evidenciar maiores diferenças e realizar as comparações;
- Elitismo –. Notou-se também que a utilização dos indivíduos selecionados na formação da nova geração melhorava o desempenho final, assim esta opção foi incluída nas simulações finais;

- Cruzamento – A utilização do cruzamento em várias partes melhora o desempenho, mas este melhor resultado, ainda assim, deveria ser testado em simulações com mais gerações;
- Mutação – Apesar da taxa de mutação ser apresentadas como um método secundário nos AG, a sua utilização melhora substancialmente a performance do algo rimo. Decidiu-se que as taxas de mutação a serem utilizadas nas simulações finais seriam de 10 e 20%.

Finalmente, foram utilizados os seguintes parâmetros para possibilitar a comparação entre os métodos para uma simulação com 500 gerações. Os parâmetros utilizados e mantidos constantes para todas as simulações estão apresentados na tabela 13:

Tabela 13: Parâmetros mantidos constantes para novas simulações do AG.

Parâmetros	Valores
População Inicial	50
Função Avaliação	
Mudança da função objetivo	0,8
Linear	0,6
Método de Seleção	
Elitismo	3%
Cruzamento	
Intervalo de cruzamento	0,85
Número de Gerações	500

Finalmente, os parâmetros escolhidos para possibilitar a comparação entre os diversos métodos são apresentados na tabela 14:

Tabela 14: Valores dos parâmetros utilizados nas simulações finais do AG

Parâmetros	Valores	
	Mínimo	Máximo
Método de Seleção		
Roleta		
Torneio	4%	
Ranking	1,5	
Cruzamento		
(2 a 10 pontos)	2	10
Mutação	10%	20%

Os valores finais das simulações são apresentados no gráfico 08:

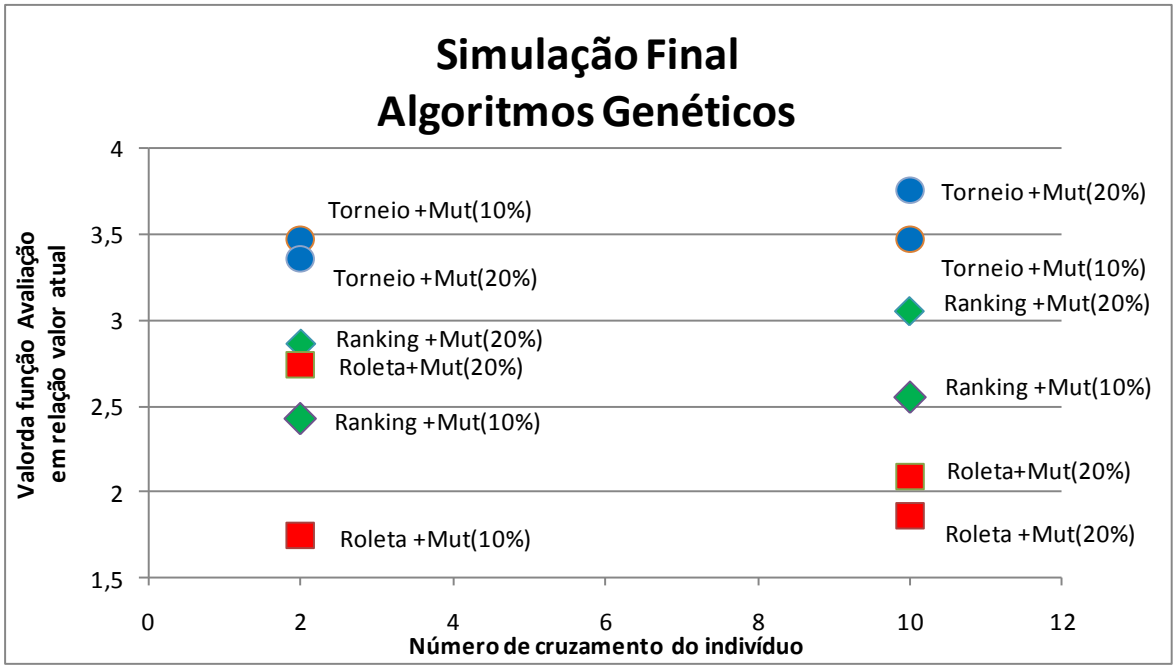

Gráfico 08 – Resultados das simulações finais do AG.

O gráfico 08, apresenta os resultados obtidos, com os parâmetros escolhidos para as simulações finais, para comparação dos métodos e parâmetros do Algoritmo Genético. No eixo das abscissas, representa-se o numero de cruzamentos possíveis n. Nas ordenadas estão os valores da função avaliação dos indivíduos, esses estão referidos à simulação base, com 419 conjuntos.

O objetivo deste gráfico é identificar quais são as melhores combinações de métodos/parâmetros para o problema em análise. Observa-se que a utilização do método de seleção através dos torneios apresentou resultados, consistentemente, superiores à utilização do método através do ranking que por sua vez apresentou valores superiores à seleção através da roleta. Observou-se que a utilização de taxas crescentes de cruzamentos e mutação, também, melhora o desempenho dos AG, para o problema em questão.

Pode-se observar que em quaisquer dos métodos/parâmetros utilizados as configurações finais dos conjuntos tiveram um desempenho superior à atual configuração com 419 conjuntos. No pior caso, houve uma redução de 43% do valor atual e no melhor caso uma redução de 73%, demonstrando que a utilização da otimização no processo trouxe ganhos.

A seguir são apresentadas as simulações e análises realizadas para o Algoritmo de seleção slonal.

5.2 REDISTRIBUIÇÃO DOS CONJUNTOS DE CONSUMIDORES EM NOVOS CLUSTERS ATRAVÉS DO ALGORIMO DE SELEÇÃO CLONAL.

Várias simulações foram feitas com a finalidade de testar os diversos parâmetros de entrada dos Algoritmos Genéticos. As seguintes variáveis podem ser modificadas pelo usuário:

- População Inicial;
- Taxa de mutação por indivíduo;
- Número máximo de Clones por indivíduo;
- Número de Gerações.

A figura 38 apresenta a tela do SOA em que modificam-se os parâmetros. Para cada conjunto de parâmetros foram consideradas 10 simulações.

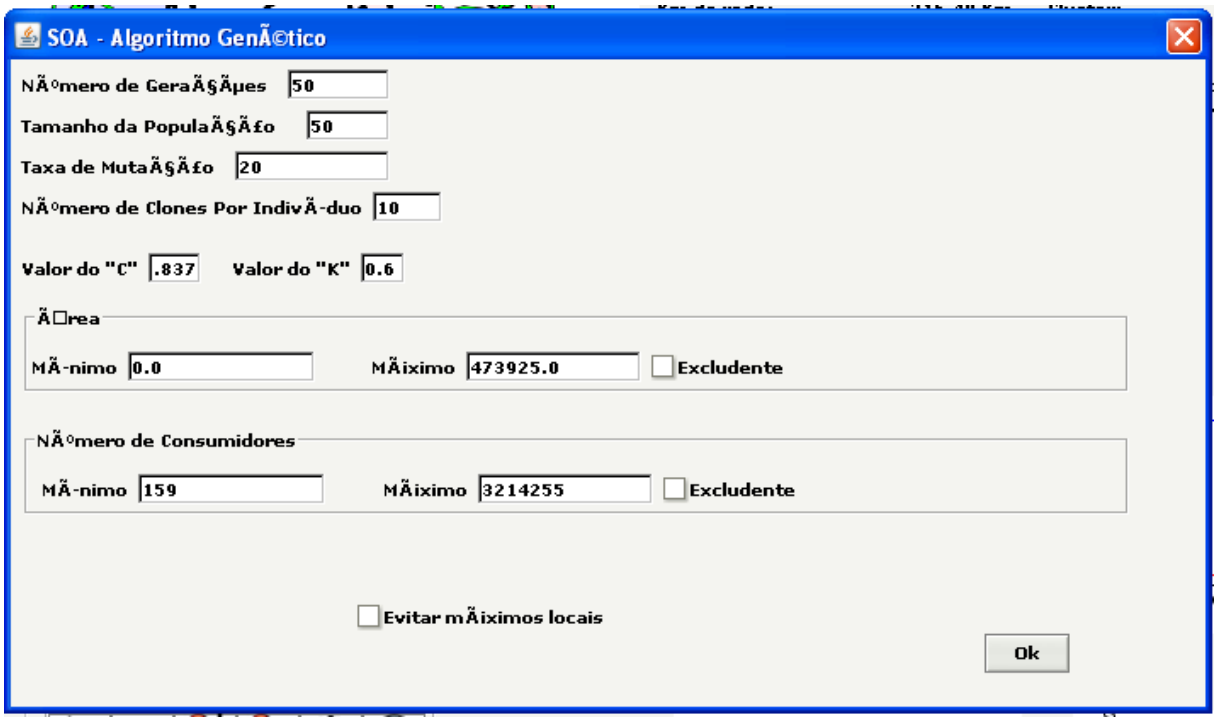

Figura 38 – Parâmetros do Algoritmo de Seleção Clonal

Exatamente como nos teste realizados nos Algoritmos Genéticos, foram feitos vários testes iniciais com a finalidade de estabelecer padrões de comportamento do Algoritmo de Seleção Clonal. A partir daí, foi possível determinar os parâmetros que seriam inicialmente utilizados, que são apresentados na tabela 15. Para avaliação do desempenho dos diferentes parâmetros e depois compará-los, foram realizadas 05 simulações. Finalmente, o método de seleção utilizado permite que cada indivíduo ou um de seus clones participem da próxima geração.

Tabela 15 – Valores dos parâmetros analisadas para o ASC.

Parâmetros	Valores
Tamanho da População	50
Taxa de Mutação por Indivíduo	10%
Número de Clones	5
Número Gerações	30

A análise dos gráficos demonstrou um desempenho extremamente comportado, sem que ocorresse qualquer modificação no melhor indivíduo ao longo das gerações, com a média da população crescendo muito lentamente. Isto motivava que o sorteio da população inicial determinasse o desempenho do Algoritmo de Seleção Clonal. Tornou-se evidente a necessidade de modificação do algoritmo básico, modificando parâmetros e métodos, para uma nova simulação.

As alternativas de modificações e parâmetros são menores nos Algoritmo de Seleção Clonal. Buscou-se modificar inicialmente os procedimentos do algoritmo ao invés dos parâmetros. Assim, a forma inicial de seleção dos indivíduos permitia que o indivíduo ou algum de seus clones, o mais bem avaliado, passasse para a nova geração. Na nova implementação, todos os indivíduos e seus clones são avaliados em conjunto sendo que os indivíduos ou clones de melhores notas passam para próxima geração. É evidente, que, neste caso, existe a possibilidade de perda de algum indivíduo durante este processo.

Outra modificação importante foi implementada na geração do clone. Na formulação básica, a clonagem do indivíduo utilizava um operador negação. Desta forma, se no cromossomo escolhido o valor fosse 1, a operação negação tornava o valor 0, e vice-versa. Na análise dos melhores resultados já encontrados através dos AG, observou-se que os indivíduos mais conexos tenderiam a receber melhores notas.

Desta forma, estabeleceu-se probabilidades para mutação do cromossomo. Na outra implementação existiam probabilidades para modificação dos cromossomos. Assim, caso o cromossomo escolhido para mutação fosse 1, a probabilidade de torná-lo 0 (zero) não era mais de 100% e sim um valor determinado antes da simulação. De forma semelhante, no caso do cromossomo escolhido ser 0 (zero) existia uma probabilidade pré-definida que poderia ser diferente do parâmetro anterior.

Quanto aos parâmetros já existentes, foram elevadas as taxa de mutação do indivíduo e o número de clones. A tabela 16 apresenta os parâmetros utilizados. Para avaliação do desempenho dos diferentes parâmetros e depois compará-los foram realizadas 05 simulações. Os resultados das simulações são apresentados no Anexo II deste trabalho.

Tabela 16 – Valores dos parâmetros analisadas para o ASC.

Parâmetros	Valores	
Tamanho da População	50	
Taxa de Mutação por Indivíduo	20%	50%
Número de Clones	10	
Número Gerações	30	

Os gráficos, do Anexo II permitem uma análise mais detalhada. As modificações no algoritmo básico conduziram a um melhor desempenho na utilização do Algoritmo de Seleção Clonal, permitindo que os melhores indivíduos, os mais bem avaliados, fossem sendo modificados ao longo das gerações. Além disso a média das avaliações das populações tornou-se mais convergente.

Quanto aos parâmetros modificados, nota-se que o desempenho do algoritmo cresce com o número de clones sorteados, o desempenho do algoritmo com 10 clones é bastante superior ao com 5 clones por indivíduo. Evidentemente que isto eleva proporcionalmente o tempo de execução do algoritmo. O incremento da taxa máxima de mutação por indivíduo também melhorou o desempenho do Algoritmo de Seleção Clonal.

Com a finalidade de comparar os desempenhos dos Algoritmos Genético e de Seleção Clonal fez-se mais duas simulações, para 500 gerações. A tabela 17 apresenta os parâmetros utilizados nas últimas simulações, para 200 gerações:

Os resultados das simulações podem ser vistos nos gráficos 09 e 10:

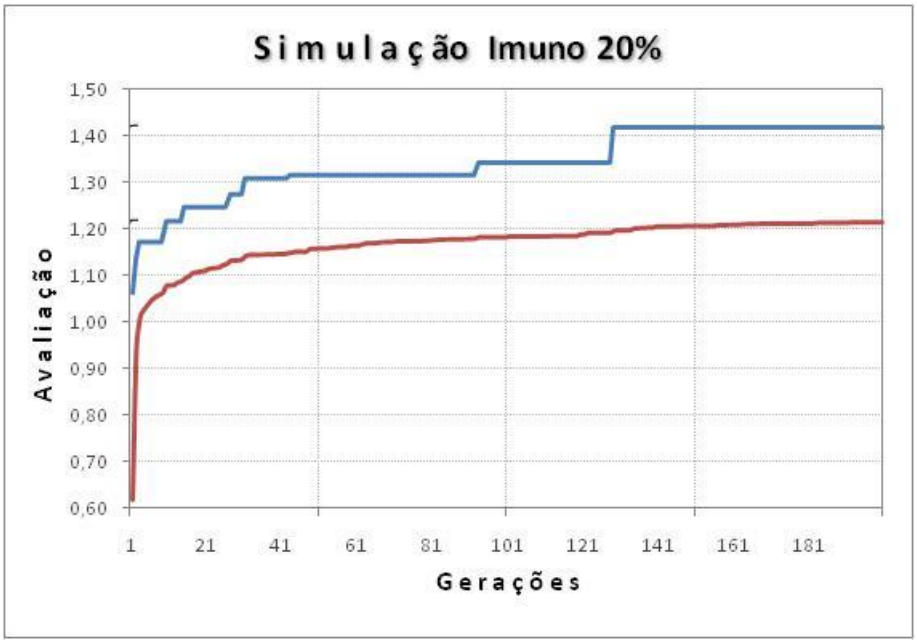

Gráfico 09 – Simulação final do ASC com taxa de mutação de 20%

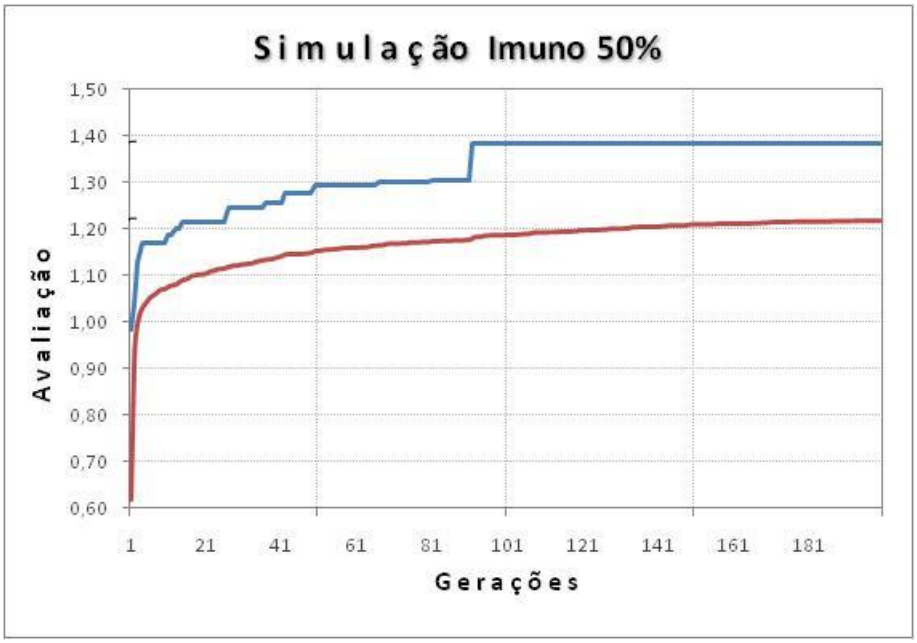

Gráfico 10 – Simulação final do ASC com taxa de mutação de 50%

Os resultados apresentados pelo Algoritmo de Seleção Clonal assemelham-se aos resultados obtidos pelo método de seleção pela Roleta nos Algoritmos Genéticos, porém longe dos resultados obtidos pelo método de seleção através do Torneio.

5.4 CONCLUSÃO DO CAPÍTULO

A partir dos resultados das simulações das diferentes combinações de métodos, parâmetros e operadores, realizadas para o problema de redistribuição dos conjuntos de consumidores, este trabalho indica um melhor desempenho para o AG. O Gráfico 11 apresenta a comparação entre os algoritmos.

Aparentemente, o número de opções de operadores e parâmetros e a possibilidade de cruzamentos com outros indivíduos/soluções permite ao Algoritmo Genético uma busca mais abrangente no espaço de soluções. Evidentemente, novas opções podem ser incluídas no Algoritmo de Seleção Clonal para torná-lo mais flexível, o que pode ser feito em novas atualizações deste estudo.

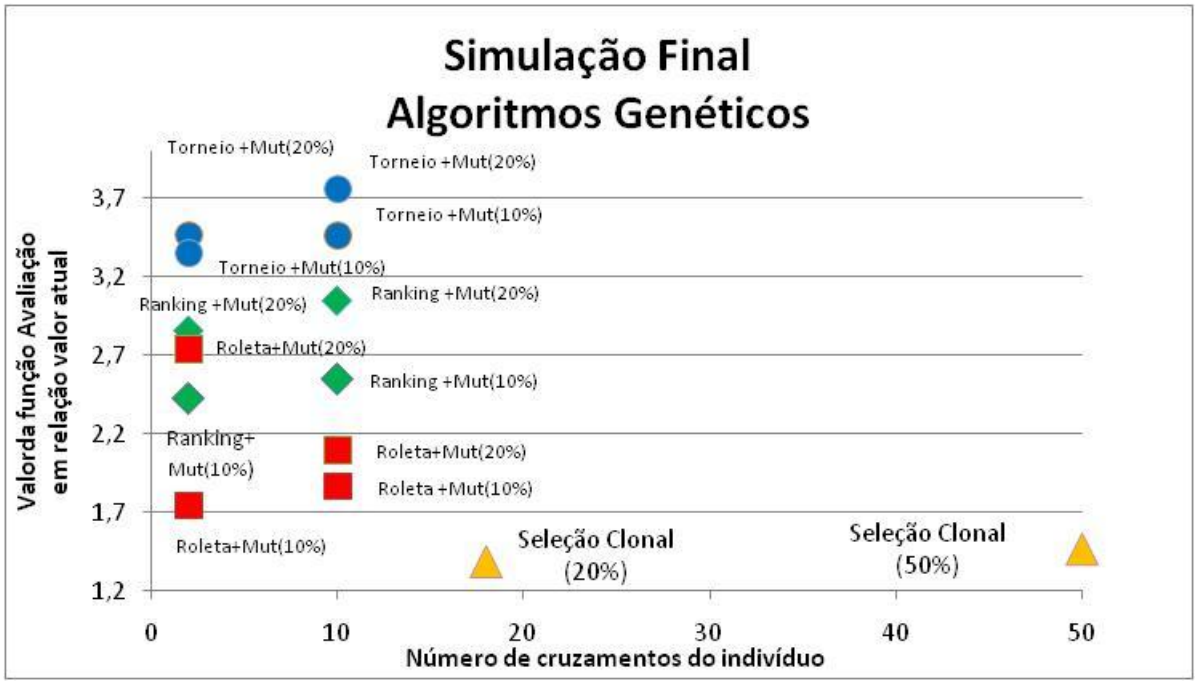

Gráfico 11 – Comparação entre o Algoritmo Genético e o Agoritmo de Seleção Clonal.

6 EXTENSÃO DA METODOLOGIA PARA CONJUNTOS GEOELÉTRICOS

Após uma década de vigência da Resolução Normativa nº 024/2000 e suas atualizações[37], a ANEEL determinou sua revisão na Audiência Pública nº 33/2009. Atualmente, toda a regulamentação sobre a qualidade da energia elétrica encontra-se disposta no Módulo 8 dos Procedimentos de Distribuição PRODIST. A Revisão 1 do PRODIST, aprovada pela Resolução Normativa n° 395/2009, revogou a Resolução n° 024/2000 e, principalmente para os estudos realizados no presente trabalho, estabeleceu novos critérios para a formação dos conjuntos de unidades consumidoras.

A motivação desta modificação pode ser explicada pela estabilidade do nível do indicador DEC, quando a expectativa era sua redução, conforme apresentado na figura 39.

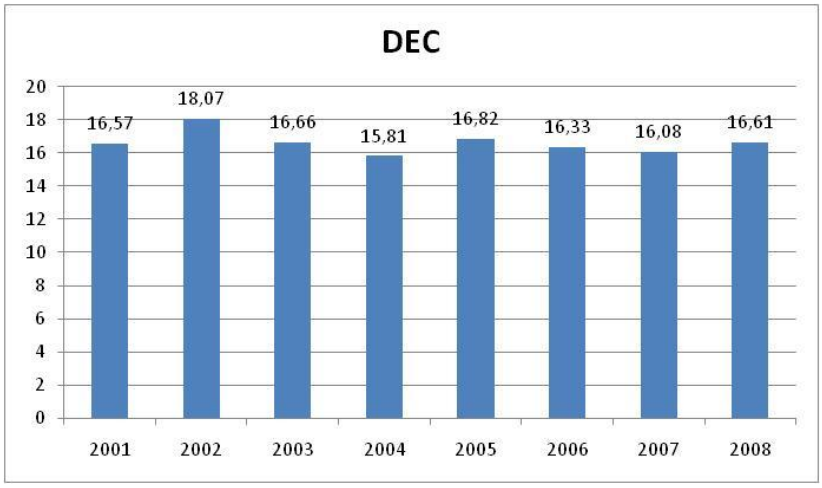

Figura 39 – Desempenho do indicador DEC (Brasil) – 2001 a 2008
Fonte:Nota Técnica 028/2010 da ANEEL

Existe, também, um consenso de que os valores de metas são elevados, e a multa paga pelas concessionárias é pequena, o que pode implicar em subinvestimento no sistema elétrico. Outro ponto bastante polêmico seria a metodologia de formação dos conjuntos previsto na Resolução Normativa ANEEL nº 024/2000.

A relativa flexibilidade existente para formação dos conjuntos permite que as concessionárias estabeleçam estes de maneira a minimizar o risco de punição por ultrapassagem das metas de continuidade estabelecidas pela ANEEL (STRAUCH, 2005). Este viés regulatório permite às concessionárias reduzir custos e priorizar seus investimentos de forma a conduzir a uma modicidade tarifária, em consonância com o atual contexto no qual estão inseridas (TANURE, 2000).

A facilidade existente para formação dos conjuntos é criticada em Hassim, (2003):

> "Os atuais conjuntos de unidades consumidoras definidos para cada concessionária não estabelecem um critério único de formação, existindo muitos casos em que um conjunto é formado por partes geográficas de diversos municípios contíguos ou até mesmo formados por diversos municípios agrupados. A não existência de um critério único de formação dos conjuntos dificulta o acompanhamento por parte da fiscalização e a definição geográfica de determinado consumidor na área de concessão da empresa."

A Audiência Pública nº 33/2009 determinou um novo critério que define as subestações de alta tensão como delimitadores dos conjuntos, buscando a homogeneização do critério de formação dos conjuntos. A alteração da área de influência do conjunto pode ocorrer, desde que haja alteração permanente na configuração do sistema que acarrete mudança nos conjuntos, e assim, a distribuidora deverá propor revisão da configuração dos conjuntos de unidades consumidoras, quando do estabelecimento dos limites anuais dos indicadores de continuidade.

Finalmente, os conjuntos serão caracterizados pelos seguintes atributos:

a) área em quilômetros quadrados (km2);

b) extensão da rede MT em quilômetros (km);

c) média mensal da energia consumida nos últimos 12 meses, em megawatt-hora (MWh);

d) total de unidades consumidoras atendidas;

e) potência instalada em kilovolt-ampère (kVA);

f) localização (sistema isolado ou interligado).

---

[37] Resolução nº 505/2001 e Resolução nº 520/2002..

A regulação por comparação ainda é prevista já que as metas de qualidade de fornecimento serão determinados pelo *Cluster* ao qual o conjunto será integrado, que será alvo de Audiência Pública específica.

6.1 ANÁLISE DA METODOLOGIA PROPOSTA PELA ANEEL

Os principais pontos analisados sobre a Metodologia Proposta pela ANEEL são explicitados a seguir.

6.1.1 Quanto ao critério para formação dos conjuntos

O critério de formação dos conjuntos foi criticado, pela falta de padronização na formação dos conjuntos. Tanure (2000) defende este ponto, considerando que a metodologia permite que as concessionárias agrupem unidades consumidoras, tendo em conta as características técnicas especificas de seu sistema elétrico, utilizando uma racionalidade técnica e econômica, visando aperfeiçoar a utilização dos seus recursos e ponderarando sua capacidade de prover condições de atendimento de forma homogênea.

HASSIM (2003) propõe que a definição dos conjuntos de unidades consumidoras seja feita por município, criando-se subconjuntos que seriam associados a bairros e regiões características de cada município, permitindo, dessa forma, uma maior visualização geográfica e uma perfeita identificação do consumidor quanto aos padrões de qualidade associados a sua região.

> "Quanto à vantagem social de se utilizar o município como critério de unidade geográfica para delimitar um conjunto, está a possibilidade da sociedade legalmente representada pelos poderes legislativo, executivo e por suas associações, poder comparar os índices da qualidade de energia elétrica de sua comunidade com os índices de outras comunidades."

Finalmente, a ANEEL através do PRODIST determinou a formação de conjuntos por subestação. A nova metodologia determina que os conjuntos deixem de ser

definidos livremente pelas concessionárias e estabelece como base para a definição dos conjuntos as subestações de distribuição.

Essa opção pode ser muito boa, na medida em que todas as concessionárias passam a ter uma mesma definição para o conjunto, melhorando a clusterização. Claro que existem Subestações que atendem áreas muito diferentes, algumas apenas a grandes cidades, outras, praticamente, só áreas industriais, e outras ainda atendem a vários municípios. Porém, se os descritores forem bem escolhidos, cada uma dessas subestações deve ser classificada dentro de um *cluster* com outras do mesmo tipo, caracterizando a pequena distância *inter cluster* e a grande distância entre *clusters* pretendida na base da teoria.

Mais uma vez, a qualidade e quantidade dos descritores é essencial para garantir a classificação adequada. Após a classificação, é preciso uma análise bem feita para identificação de elementos mal classificados, o que pode indicar baixa qualidade dos indicadores ou número insuficiente de indicadores.

As principais críticas que podem ser feitas são:

- Falta de significado para o consumidor; neste caso a divisão por municípios é mais visível;
- A área de influência das subestações pode variar muito durante uma revisão tarifária de acordo com as necessidades operacionais da concessionária;
- Como justificar metas diferentes de conjuntos vizinhos, em grandes centros urbanos de área contígua?
- Quando o comportamento do conjunto não é uniforme, mesmo que o valor médio esperado (meta de DEC) seja atingido, a dispersão dos indicadores individuais é tão grande que o número de consumidores cujos desempenhos individuais se encontram longe da média, e portanto sujeitos a multas, também é grande. Isto pode ocorrer entre consumidores rurais e urbanos dentro de uma mesma subestação.
- A formação de conjuntos por subestação pode aumentar a assimetria de tratamento entre os consumidores.

6.1.2 Quanto à análise dos atributos

Os indicadores, portanto, devem ser definidos de maneira que sejam fáceis de auditar e que caracterizem os conjuntos para que os *clusters* sejam bem representativos. Considerando os conjuntos como subestações, é possível listar uma série de indicadores que caracterizam uma subestação e que são capazes de diferenciar um tipo de subestação de outra.

É necessário testar esses indicadores, observar o resultado da clusterização e, se os *clusters* não forem suficientemente homogêneos, mudar e/ou ampliar os indicadores até que se consiga um resultado satisfatório, uma vez que a clusterização é um processo interativo. No entanto, ANEEL preferiu manter os indicadores já utilizados na resolução ANEEL 024.

Finalmente, os valores das multas foram bastante incrementados e deve estabelecer novo patamar de penalidades paga pelas concessionárias.

6.2 NOVO TRATAMENTO À CONTINUIDADE DE FORNECIMENTO

Na Resolução Normativa ANEEL nº 395/2009, o critério de formação dos conjuntos de consumidores passa a ter a área vinculada a uma subestação de distribuição. Esta aparente inflexibidade na formação dos conjuntos não impede a utilização da metodologia apresentada neste trabalho.

A Resolução Normativa ANEEL nº 024/2000 não determinava como seria a divisão dos conjuntos de consumidores, e estes conjuntos poderiam ser determinados através da área de influência de uma Subestação, ou ainda de parte do sistema elétrico limitada por uma chave de proteção e/ou manobra, conforme Figura 40.

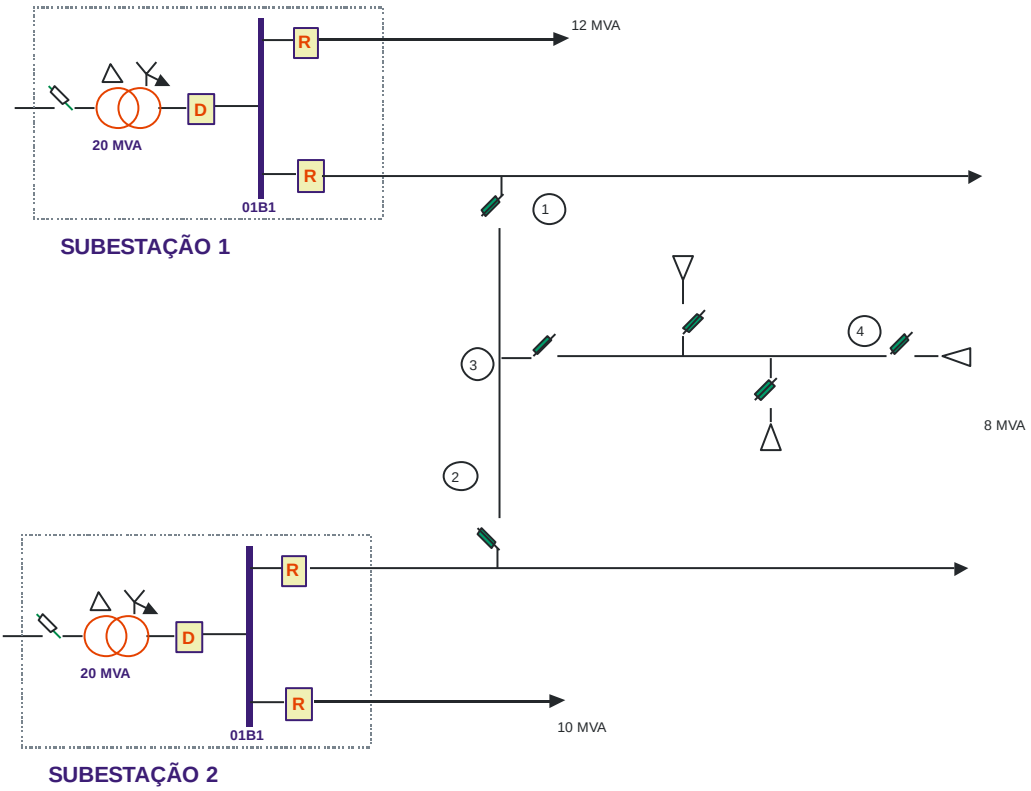

Figura 40: Redistribuição de blocos de carga entre subestações

A utilização de blocos de carga como menor conjunto de consumidores permitiria a agregação destes, de forma semelhante à redistribuição dos municípios, estudados neste trabalho. Evidentemente que as possibilidades de agregação dos blocos de cargas são menores, já que restrições técnicas próprias da distribuição de energia deverão ser consideradas.

Desta forma, a melhoria do desempenho dos indicadores de qualidade que antes podia ser analisada isoladamente, agora está associada a outros objetivos: queda de tensão, perdas, investimentos etc.

Neste caso, a otimização dos índices de qualidade do fornecimento está associada aos outros custos de distribuição de energia elétrica, conforme a função Custo Global do Serviço (CGS), que inclui todos os custos envolvidos:

$$CGS = Custo\ da\ Concessionária + Custo\ do\ Consumidor \qquad (27)$$

Onde

$$Custo\ da\ Concessionária = CINV + CPER + COM \quad (28)$$

CINV - custo do investimento

CPER - custo das perdas

COM - custo de operação e manutenção

$$Custo\ do\ Consumidor\ (imperfeições\ de\ serviço) = CEND + CDT + CQE \quad (29)$$

CEND - custo da energia não distribuída (interrupções)

CDT - custo do desvio de tensão

CQE - custo da qualidade de energia (outras imperfeições do serviço, como *flicker*, harmônicas, afundamentos e elevações de tensão etc).

Este modelo de otimização pode ser encontrado em Kagan e Bento (2009), com a ilustração de indivíduos do AG como soluções ao problema de configuração dos blocos de carga, como apresentado na Figura 41:

Indivíduo	*String*	Configuração Correspondente
$(3x5)_a$	1 2 3 4 5 6 1 0 0 1 1 1	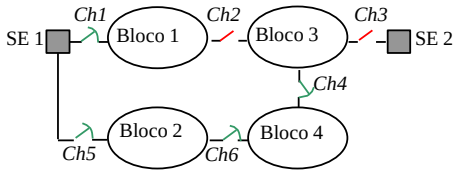
$(3x5)_b$	1 2 3 4 5 6 1 1 0 1 1 0	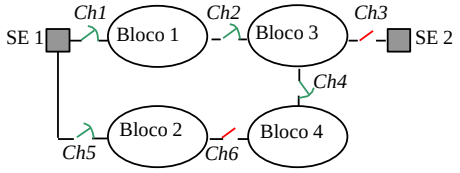
$(3)_{6°}$	1 2 3 4 5 6 1 0 0 1 1 1	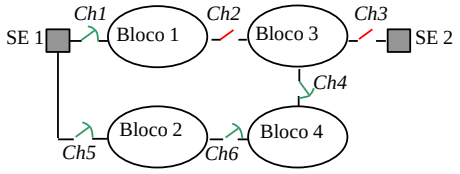
$(5)_{6°}$	1 2 3 4 5 6 1 1 0 1 1 0	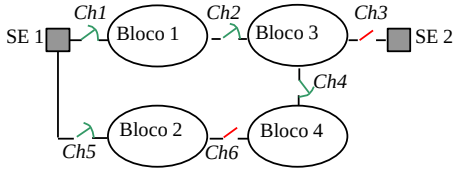

Figura 41: Modelagem das configurações do sistema de distribuição
Fonte: (KAGAN 2009)

6.3 CONCLUSÕES DO CAPÍTULO

A determinação das metas de qualidade no fornecimento de energia elétrica é uma tarefa difícil. O estabelecimento de metas mais restritivas obriga as concessionárias a novos investimentos em sua rede de distribuição, nas áreas de operação e manutenção. Inversamente, a falta da qualidade, através dos custos das interrupções, danos elétricos, e/ou perda de via útil dos equipamentos. Em qualquer dos contextos, o consumidor arcará com custos extras. A Figura 42 apresenta o problema de forma gráfica..

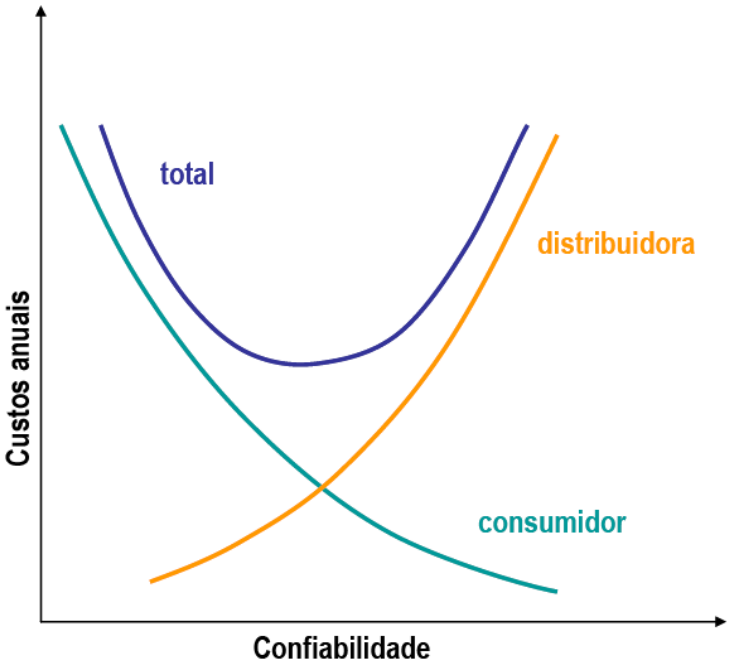

Figura 42 - Custos totais associados à confiabilidade
Fonte: Nota Técnica nº 064/2009-SRD/ANEEL

A Resolução Normativa 024/ANEEL/2000 atualizou, após vinte anos, a regulamentação sobre continuidade de serviços dentro de um novo contexto sócio-econômico. A Privatização dos serviços, a criação da agência reguladora, a introdução da metodologia de tarifação através do *Price Cap*, e outras inovações regulatórias impuseram às concessionárias a necessidade de rotinizar a redução de custos.

Este viés regulatório determina a busca pela concessionária da otimização dos seus custos e investimentos tendo como referência uma regulamentação que determina maiores multas por ultrapassagem de metas de qualidade. Neste contexto, surge este projeto com a necessidade das empresas aperfeiçoarem a utilização dos seus recursos, e prover as condições de atendimento adequadas aos consumidores.

Por seu lado, a ANEEL certificando-se de que os indices de qualidade mantiveram-se estáveis nos últimos anos, apesar das evidências de que estes poderiam melhorar, elevou as metas de qualidade e as penalidades. Esta sinalização do órgão regulador direcionará maiores investimentos na rede pela concessionária.

Novamente, as concessionárias procurarão otimizar seus recursos, com a construção de ferramentas de otimização para determinar o nível ótimo dos indicadores de continuidade de fornecimento. Este jogo, desde que bem administrado, permite a construção de níveis de qualidade e tarifários adequados para o consumidor de energia elétrica.

7 CONCLUSÕES DO TRABALHO

7.1 ASPECTOS GERAIS

Os estudos traduzidos neste trabalho tiveram origem no projeto de pesquisa e desenvolvimento intitulado “Metodologia para formação de conjuntos de consumidores e suas metas de continuidade, Projeto P&D 13 – 3º Ciclo (2002/2003)”, o qual foi desenvolvido pela Coelba e aprovado com o objetivo de desenvolver metodologia para determinação de agrupamentos de unidades consumidoras, de modo a otimizar a aplicação de recursos em expansão, operação e manutenção das redes de distribuição e minimizar riscos de punição pelo órgão regulador sem redução da qualidade fornecida.

Naquele momento, as concessionárias de distribuição tateavam as conseqüências da recém editada resolução ANEEL 024/2000, e a flexibilidade existente para formação dos conjuntos permitiu que as concessionárias estabelecessem seus conjuntos de diversas formas, sem que houvesse um consenso, o que justificou o desenvolvimento do projeto de pesquisa. A pesquisa iniciou-se com a análise da formação dos agrupamentos de consumidores.

A facilidade no uso do software desenvolvido (figura 32), esbarrou na incapacidade de um análise manual, no elevadíssimo número de possibilidades de conjuntos que podiam ser gerados. A inclusão de uma metodologia de otimização foi um passo natural, em uma segunda etapa deste projeto. O Projeto de pesquisa “Otimização da Multa Global de Continuidade Através de Técnicas de Análises Multivariadas, Programa de P&D - Ciclo 2006-2007 - P&D 0047–026/2007” atendeu a esta lacuna.

A Reestruturação dos Setores de Energia Elétrica, cuja definição de um novo modelo, impôs a redução de custos através da concorrência ou a simulação desta, através da introdução da metodologia de tarifação através do *Price Cap* é a origem deste trabalho. Neste modelo a redução de custos está em oposição à qualidade do

fornecimento, que necessita de investimentos. Por outro lado, investimentos determinam a tarifa a ser praticada. Neste contexto, as concessionárias precisam utilizar seus recursos com eficiência, reduzindo os seus custos e fornecendo energia com qualidade exigida pela ANEEL.

O ponto central deste trabalho reside no fato da possibilidade das concessionárias determinarem a melhor forma de agrupar os seus consumidores de forma a utilizar ao máximo seus recursos operativos, evitando multas por fornecimento de energia elétrica fora da qualidade prevista nas resoluções da ANEEL. Apesar das modificações apresentadas nas novas normas de qualidade do fornecimento de energia elétrica, a metodologia proposta neste trabalho continua válida.

7.2 LIMITAÇÕES DA METODOLOGIA

As características do problema de redistribuição de consumidores assemelham-se ao problema de redistribuição de eleitores – *Political Redistriting* e a redistribuição de alunos – *School Redistriting* processos comuns nos Estados Unidos. Em ambos os casos as áreas dos distritos de votação ou área de influência das escolas devem ser contínuas e concisas e estão sujeitas as restrições específicas de cada problema.

O problema de redistribuição de consumidores é um problema de grande complexidade computacional devido a explosão combinatória decorrente das possibilidades de agrupamentos diferentes. Este problema tiorna-se mais complexo com a necessidade da contigüidade das áreas, tornando-se um problema NP completo.

Algumas limitações metodológicas podem ser apresentadas:

- Para solucionar o problema forma utilizados os algoritmos evolutivos, especificamente os Algoritmos Genéticos e o Algoritmo de Seleção Clonal. Estes algoritmos são heurísticas, isto é, possuem uma metodologia que

caminha para a solução ótima, mas não necessariamente a encontra. Como foi apresentado, estes algoritmos apresentam um bom desempenho para os problemas de explosão combinatorial;

- Uma das limitações da metodologia está na escolha da função avaliação. A função avaliação é determinada pela diferença entre a Meta do DEC do conjunto e o DEC real do conjunto. No caso base analisado, que foi a divisão por município realizada pela concessionária este valor é negativo, -501,3734. Mesmo que a otimização leve a valores positivos não significará a ausência de multas, já que os valores do DEC são médias.
- Outro ponto importante, relacionado à função avaliação e a desconsideração do número de consumidores, o que pode induzir a uma maior quantidade de multas. Por exemplo, um conjunto com grande número de consumidores pode apresentar uma função avaliação negativa, mesmo que o valor global da função seja ótimo. Provavelmente este conjunto influenciará negativamente o valor da multa global;
- Na ausência de um valor absoluto de referência na determinação do valor da função avaliação, utilizou-se o valor atual da função avaliação como referência;
- Finalmente, pode-se citar que a metodologia prevê a utilização de um único ano como referência. A utilização de vários anos ou até mesmo uma projeção deste valores seria mais adequada, pois as metas têm validade de 4 anos.

7.3 CONTRIBUIÇÕES

O projeto de pesquisa teve como finalidade oferecer ferramenta computacional para determinação da qualidade de fornecimento decidindo sobre a melhor forma de redistribuir seus consumidores. Diferentemente, esta Tese desenvolvida sobre este trabalho, tem o objetivo de discutir, analisar, comparar e concluir sobre os seus fundamentos, contribuindo para discussões sobre os temas analisados.

Neste trabalho duas contribuições desta pesquisa são apresentados. Em primeiro lugar faz-se uma análise da evolução das normas de qualidade do fornecimento, especificamente a continuidade do serviço, enfatizando suas diversas características. Em seguida, são apresentados os estudos para otimização do processo de reconfiguração dos conjuntos de consumidores para uma área de concessão.

Quanto aos aspectos de continuidade de fornecimento, foram analisados três momentos distintos. No primeiro momento quando as Concessionárias ainda pertenciam ao Estado e a universalização dos serviços públicos de eletricidade estava distante, surgiram as primeiras legislações/normas sobre qualidade de fornecimento de energia elétrica. Naquele momento a expansão das redes para atendimento aos consumidores era mais importante e a qualidade do fornecimento era uma preocupação nascente.

A Resolução Normativa 024/ANEEL/2000 atualizou após vinte anos, a regulamentação sobre continuidade de serviços dentro de um novo contexto sócio-econômico. A Privatização dos serviços, a criação da agência reguladora, a introdução da metodologia de tarifação através do *Price Cap*, e outras inovações regulatórias impuseram às concessionárias a necessidade de definir rotinas para redução de custos.

Finalmente, após uma década de implantação da Resolução Normativa 024/ANEEL/2000, a ANEEL aprofundou a regulação, elevando as multas de forma a direcionar as ações das concessionárias na melhoria das metas de qualidade. A determinação das metas de qualidade no fornecimento de energia elétrica é uma tarefa difícil, desta forma espera-se um contínuo aperfeiçoamento das normas de qualidade, visando o equilíbrio entre tarifas e qualidade.

O caminho para introduzir a otimização na Metodologia passou por diversas etapas, e é outra grande contribuição desta Tese. A tentativa de utilização de Programação Inteira, especificamente para o método *Branch and Bound*, redundou em um problema de tempo de execução, mesmo dividindo-se a área de concessão em pequenas partes, e para pequenas partes do dois problemas de difícil solução.

A utilização dos Algoritmos Genéticos apresentou-se então como a solução para metodologia de otimização. Uma modelagem inadequada determinou uma dificuldade intransponível para sua utilização. Esta dificuldade forçou a utilização de Sistemas Imunológicos Artificiais, especificamente o Algoritmo de Seleção Clonal. A possibilidade de clonar o indivíduo/solução pulou o obstáculo da formação dos indivíduos e a geração de novos indivíduos.

Uma nova modelagem para o problema determinou a possibilidade de utilização dos Algoritmos Genéticos e Agoritmo de Seleção Clonal na sua forma canônica. Após ajustes de diversos parâmetros em ambos os algoritmos, concluiu-se que os resultados obtidos através do método de seleção por torneio do Algoritmo Genético apresentava uma resposta superior quando aplicados ao problema de reconfiguração dos conjuntos de consumidores.

A maior quantidade de opções de parâmetros no AG em relação ao ASC, permite uma maior flexibilidade em busca de novas soluções/indivíduos dentro do espaço de soluções. Por outro lado, o Algoritmo de Seleção Clonal permite a busca das melhores soluções mais próximas do indíviduo, o que pode ser interessante em alguns casos.

Enfim, para este problema, a reprodução sexuada, base conceitual dos Algoritmos Genéticos, é mais vantajosa do que a reprodução assexuada, metodologia central do Algoritmo de Seleção Clonal.

7.4 SUGESTÕES PARA FUTUROS ESTUDOS

Alguns debates que poderão ser realizados em próximos estudos:

- Quanto a continuidade de fornecimento, a análise dos custos que envolvem a qualidade de fornecimento, deve ser continuamente pesquisada. Diversas perguntas devem ser respondidas:
    - Quanto custa a confiabilidade exigida na tarifa?

- O valores das multas direcionam as concessionárias a melhorar o seu desempenho?

- Quanto às ferramentas de otimização:
  - Problemas de explosão combinatorial serão cada vez mais freqüentes. No setor elétrico estas ferramentas de otimização poderiam ser utilizadas em outros problemas, como melhoramentos em redes secundárias, planejamento de áreas urbanas, no planejamento do sistema de geração no Brasil, de forma a consolidar os conceitos destas metodologias, dentre outros;
  - Um caminho a ser percorrido com a utilização das características das duas técnicas de otimização para problemas de grande complexidade computacional, principalmente os problemas em que encontram-se explosões combinatórias.
  - Utilização de ferramentas de inteligência computacional, como lógica fuzzy ou redes neurais artificias para melhorar o desempenho das heurísticas.

REFERÊNCIAS

ALBAN, M. **Crescimento sem emprego**. Salvador. Casa da Qualidade, 2001.

ARAÚJO, V.V., ARAÚJO, R.J.P., Meireles, C.P. Depth-limited search and genetic algorithms for primary network planning optimization. In: 30º CILAMCE, Búzios, 2008.

CARVALHO, A.C.F. Notas de aula: algoritmos genéticos, 1999. Disponível em: http://www.icmc.usp.br/~andre/research/genetic. Acesso em jan de 2009.

CARVALHO FILHO, D.M. **Modelo de otimização de estações radiobase baseado em sistemas imunológicos artificiais**. Tese de Doutorado, Universidade Federal de Campina Grande, 2008.

CASTRO, L.N. **Engenharia imunológica: desenvolvimento de ferramentas computacionais inspiradas em sistemas imunológicos artificiais.** Tese de Doutorado, Universidade Estadual de Campinas, 2001

DESJARDINS, M. et al.. **Heuristic Search and Information Visualization Methods for School Redistricting.** Department of Computer Science and Electrical Engineering, University of Maryland Baltimore County. Disponível em: http://maple.cs.umbc.edu/papers/iaai06-dj.pdf. Acesso em fev de 2009.

Brasil. Constituição Federal do Brasil,1988. Constituição da Repúlblica Federativa do Brasil de 05 de outubro de 1988. Brasília, 1988.

CORMEN, Thomas H., LEISERSON, Charles E., RIVEST, Ronald L., STEIN, Clifford. **Algoritmos: Teoria e Prática.** 2ª ed..Rio de janeiro: Campus, 2002.

FALEIROS, T. P. Abordagem imunológica para elaboração automática de quadros horários. Projeto Final de Curso, Universidade Federal de Goiás - DCC, 2005.

FRANÇA, F. O. **Algoritmos bio-inspirados aplicados à otimização dinâmica** Dissertação de Mestrado, Universidade Estadual de Campinas, 2005.

FREITAS, F.H. **A regulação das telecomunicações no Brasi**l. Tese de Doutorado. Escola de Administração, UFBA – Salvador 2000.

HAIR, J.F., TATHAM, R.L., ANDERSON, R.E,. BLACK, W. **Análise multivariada de dados,** 5ª ed. São Paulo: Bookman, 2005.

HASSIM, E.S. **Continuidade dos serviços de distribuição de energia elétrica: análise regulatória, correlação dos indicadores e metodologia de compensação ao consumidor.** Dissertação de Mestrado, Universidade de Brasília, dezembro de 2003.

HILLIER, F.S., LIEBERMAN G.J. **Introdução à pesquisa operacional**. São Paulo. Editora Campus, 1986.

GILL, S.S., CHANDEL, R., and CHANDEL, A. **Comparative study of ant colony and genetic algorithms for VLSI circuit partitioning,** International Journal of Electrical and Computer Engineering,2009, 4(6): 00 -00.

GHIRARDI, A G. **A presença da agência reguladora estadual e a qualidade dos serviços de distribuição de energia elétrica.** In: I Congresso Brasileiro de regulação de serviços Públicos Concedidos, 2000, Salvador. Anais, Salvador (CD-ROM)

GOLDBARG, M.C., LUNA, H.P.L., **Otimização combinatória e programação Linear: modelos e algoritmos,** 2ª ed. Rio de janeiro: Elsevier, 2005.

GOUVEA, M. R., et al.. **Avaliação do custo cocial de interrupção do fornecimento de energia elétrica do lado da demanda no Estado de São Paulo**, In: Seminário Nacional de Produção e Transmissão de energia Elétrica, 2001

KAGAN, N., SCHMIDT, H.P., OLIVEIRA, C.C.B., KAGAN, H. **Métodos de otimização aplicados a sistemas elétricos de potência.** São Paulo: Blucher, 2009.

KAGAN, N., BENTO, E.P. Algoritmos genéticos e variantes na solução de problemas de configuração de redes de distribuição. Revista Controle & Automação 2008, 19(3) jul/ago/set, 302 -315.

LACERDA, E.G.M, CARVALHO, A.C.P.L. Introdução aos algoritmos genéticos. In: Galvão, C.O., Valença, M.J.S. (orgs.) Sistemas inteligentes: aplicações a recursos

hídricos e ciências ambientais. Porto Alegre: Ed. Universidade/UFRGS : Associação Brasileira de Recursos Hídricos. 1999, p. 99-150.

Lei 8.987, de fevereiro de 1995. Disponível em: http://www.planalto.gov.br/ccivil.../Leis. Acesso em fev de 2009.

LOBO F.G., and LIMA, C.F.. **A review of adaptive population sizing schemes in genetic algorithms**. In Proceedings of the 2005 Workshop on Parameter Setting in Genetic and Evolutionary Algorithms (PSGEA 2005), part of GECCO 2005. ACM Press, 2005.

LUDERMIR, Teresa B.. Nota de Aula - algoritmos genéticos, 2004, Disponível em http:www.cin.ufpe.br/~tbl/Aulas/SI/ag-tbl.ppt. Acesso em: out de 2010.

Nota Técnica nº 064/2009-SRD/ANEEL. Disponível em http://www.aneel.gov.br/aplicacoes/consulta_publica/documentos, Acesso em jan de 2010.

SILVA, A. L. M., MORAIS V. W. C., ASSIS, L. P., ANDRADE A. V.. **Comparação entre duas abordagens bio-inspiradas aplicadas ao Problema de roteamento de veículos com coleta e entrega Simultâneas** In XLII Simpósio Brasileiro De Pesquisa Operacional, São Bento, RS, 2010.

SPIEGEL, M.R.Estatística. 3ª ed..Makron Books, 1993 – (Coleção Schaun)

MAS-COLELL, A., WHINSTON, M.D. e GREEN, J.R., **microeconomic theory**. Oxford Economic, 1995. Disponível em http://www.2dix.com/pdf-2010/mas-colell-a-whinston-md-green-jr.-microeconomic-theory.-oxford-university-pdf.php. Acesso em jan de 2009.

MASUTTI, T.A.S., CASTRO, L.N. Um algoritmo imunológico para a solução do problema do caixeiro viajante. Universidade Católica de Santos, 2008.

MEHROTRA, A., NEMHAUSER, J. **An optimization based heuristic for Political Districting.** Disponível em http://mansci.journal.informs.org/cgi/content. Acesso em fev de 2008.

PASSANEZI FILHO, Reynaldo. **Privatização e reforma institucional da infra-estrutura no Brasil: em busca de ganhos fiscais de eficiência econômica.** Tese

de Doutrado Faculdade de Economia, Administração e Contabilidade da USP. São Paulo 1998.

PIRES, J.C.L. **Reestruturação competitiva e regulação nos setores de energia elétrica e de telecomunicações. Tese de Doutoramento.** Instituto de Economia. URFJ. Rio de Janeiro – 1999.

PIRES, J C L., PICCININI, M.S. **Mecanismos de regulação tarifária do setor Elétrico: a experiência internacional e o caso brasileiro.** Rio de Janeiro – Textos para Discussão do BNDES, 1998. Disponível em http//www.bndes.gov.Br>. Acesso em set.2000.

Portaria DNAEE 046/78. Ministério de Minas e Energia. Departamento Nacional de Águas e Energia Elétrica, 1978.

Portaria DNAEE 047/78. Ministério de Minas e Energia. Departamento Nacional de Águas e Energia Elétrica, 1978.

Relatório SCOM 01.02 - **Índices operativos: desempenho sistema de distribuição do Comitê de distribuição** – CODI, 1977.

Resolução/ANEEL n.° 024/2000. Disponível em http// www.aneel.gov.br/cedoc/res2000024.pdf. Acesso em set.2000.

Resolução/ANEEL n.° 505/2000. Disponível em http// www.aneel.gov.br/cedoc/res2000505.pdf. Acesso em set.2000.

Resolução Normativa n° 395/2009, Disponível em http// www.aneel.gov.br/cedoc/res2009395.pdf. Acesso em fev.2010.

Audiência Pública nº 33/2009. Disponível em http://www.aneel.gov.br/aplicacoes/consulta_publica/documentos/Nota%20T%C3%A9cnica_0033_SRD.pdf. Acesso em fev.2010.

Módulo 8 dos Procedimentos de Distribuição PRODIST. Disponível em http://www.aneel.gov.br/area.cfm?idArea=82. Acesso em ago de 2010.

Nota Técnica 028/2010 da ANEEL. Disponível em http://www.aneel.gov.br/aplicacoes/consulta_publica/documentos/Nota%20T%C3%A9cnica_0028_SRD.pdf. Acesso em ago.2010.

ROSA, P.; TOLMASQUIM, M., PIRES, J.C. **A reforma do setor elétrico no Brasil e no mundo: uma visão crítica.** Rio de Janeiro: Relume & Dumará, 1998.

STRAUCH, M. ,ARAÚJO, R.,VALENTE, A. PEREIRA, X. **Relatório final do projeto de pesquisa metodologia para formação de conjuntos de consumidores e suas metas de continuidade** – Salvador: ANEEL, 2005.

STRAUCH, M. ,ARAÚJO, R.,VALENTE, A. PEREIRA, X. R**elatório final do projeto de pesquisa metodologia de otimização da multa global de continuidade através de técnicas de análises multivariadas.** – Salvador: ANEEL, 2009.

TAHAN, C.M.V. ; ARANGO, H.; GOUVEA, M.R. . **Indicadores de qualidade: determinação dos padrões.** In: II Congresso Brasileiro de Regulação de Serviços Públicos Concedidos, 2001, São Paulo. II Congresso Brasileiro de Regulação de Serviços Públicos Concedidos, 2001.

TANURE, J.E.P.S. **Análise comparativa de empresas de distribuição para o estabelecimento de metas de desempenho para indicadores de continuidade do serviço de distribuição.** Dissertação de Mestrado, EFEI, Itajubá, Novembro de 2000.

ZHANG, Y., et al. **A hardware/software partitioning algorithm based on artificial immune principles.** Disponível em http://nical.ustc.edu.cn/papers/ywzbx07.pdf. Acesso em fev de 2009.

ANEXO I
SIMULAÇÕES COM ALGORITMOS GENÉTICOS

Simulação com algoritmos genético Tipo 1

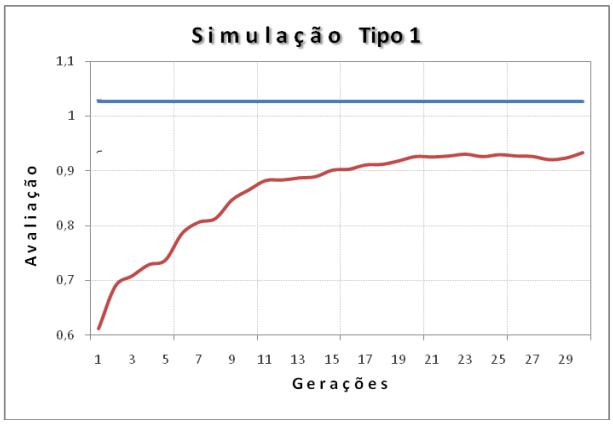

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Roleta	
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 12 - Simulações com algoritmos genéticos tipo 1

Simulação com algoritmos genético Tipo 2

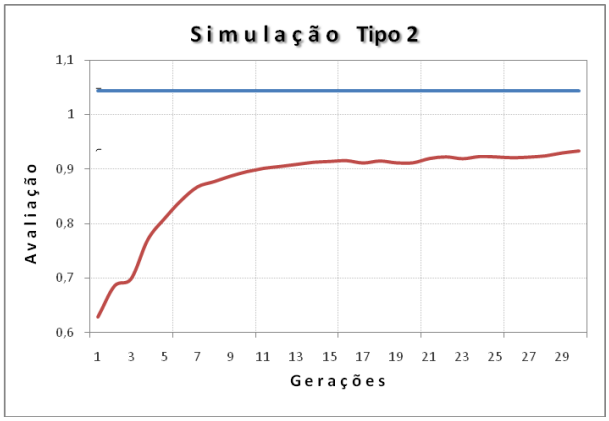

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Roleta	
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 13 - Simulações com algoritmos genéticos tipo 2

Simulação com algoritmos genético Tipo 3

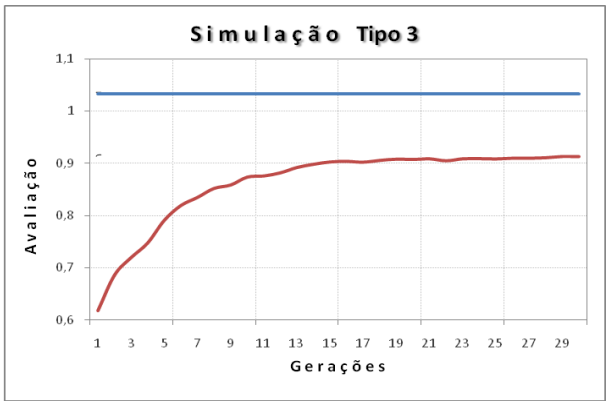

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Roleta	
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 14 - Simulações com algoritmos genéticos tipo 3

Simulação com algoritmos genético Tipo 4

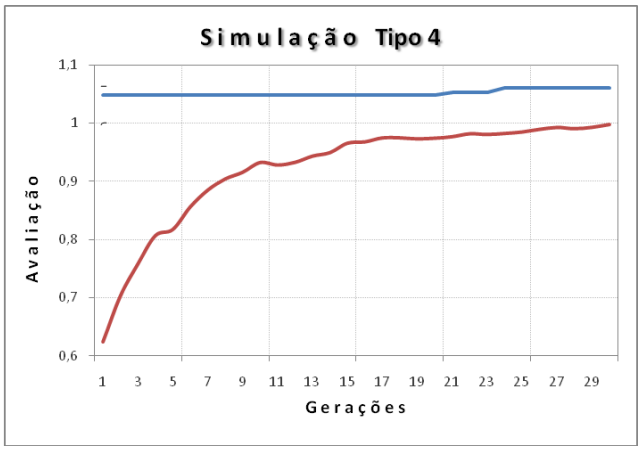

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Roleta	
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 15 - Simulações com algoritmos genéticos tipo 4

Simulação com algoritmos genético Tipo 5

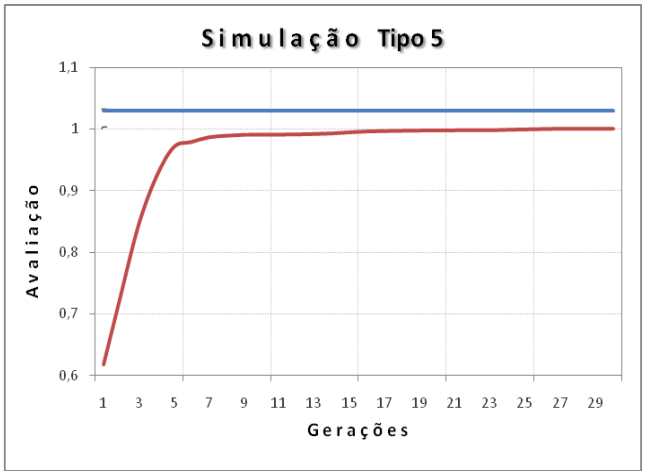

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**2**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 16 - Simulações com algoritmos genéticos tipo 5:

Simulação com algoritmos genético Tipo 6

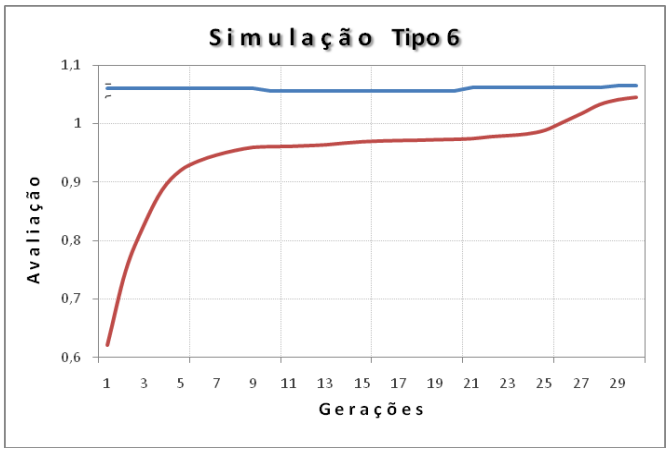

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**2**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 17 - Simulações com algoritmos genéticos tipo 6

Simulação com algoritmos genético Tipo 7

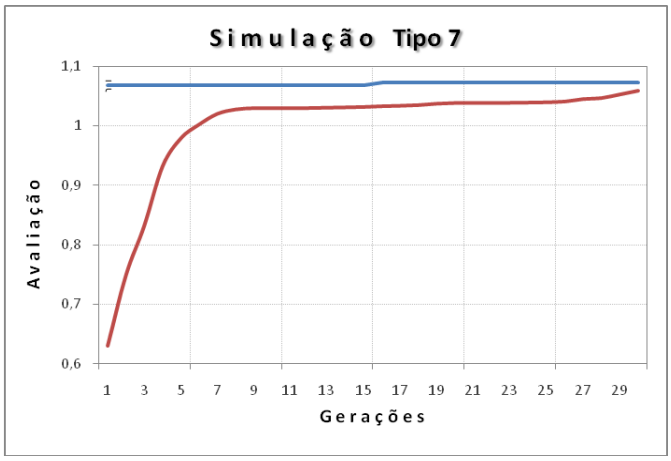

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**2**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 18 - Simulações com algoritmos genéticos tipo 7

Simulação com algoritmos genético Tipo 8

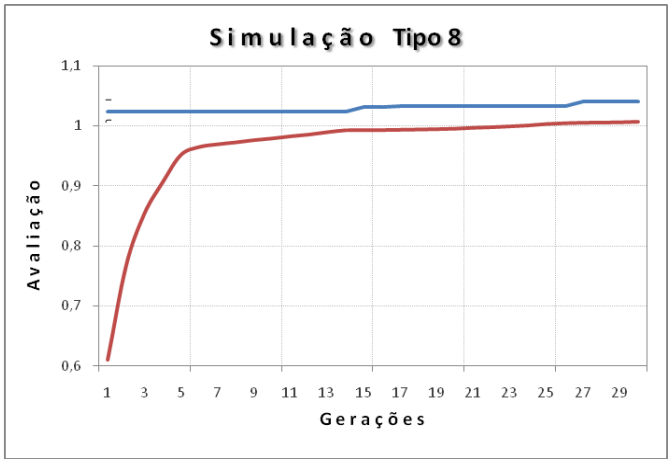

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**2**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 19 - Simulações com algoritmos genéticos tipo 8:

Simulação com algoritmos genético Tipo 9

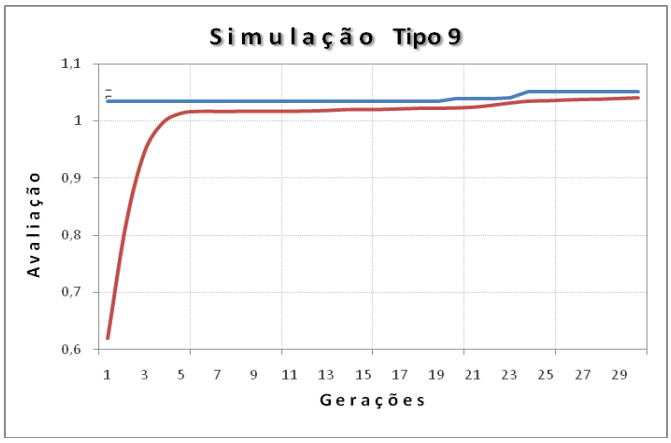

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**4**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 20 - Simulações com algoritmos genéticos tipo 9

Simulação com algoritmos genético Tipo 10

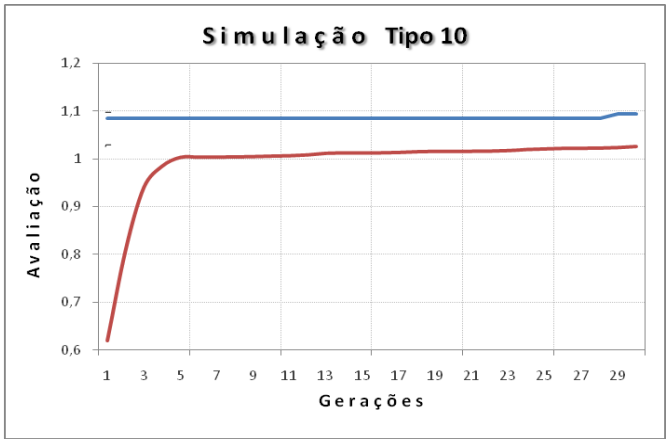

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**4**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 21 - Simulações com algoritmos genéticos tipo 10

Simulação com algoritmos genético Tipo 11

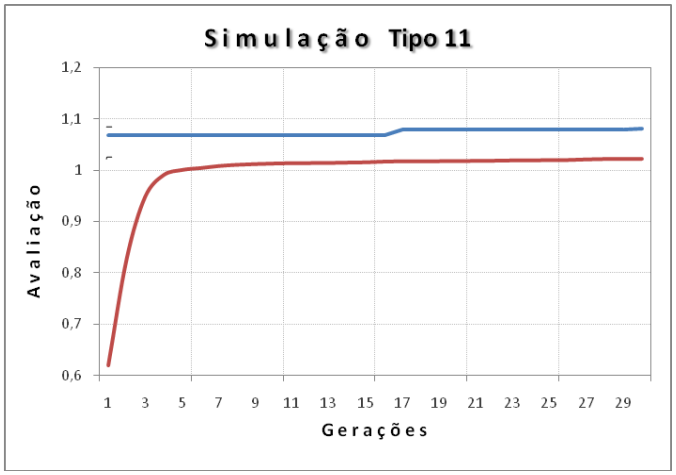

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**4**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 22 - Simulações com algoritmos genéticos tipo 11:

Simulação com algoritmos genético Tipo 12

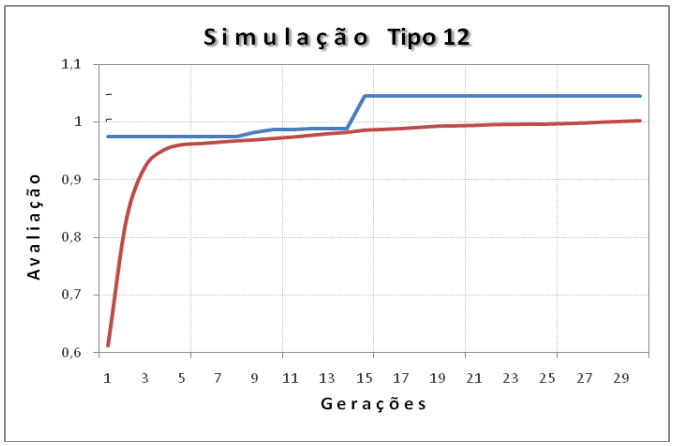

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Torneio	**4**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 23 - Simulações com algoritmos genéticos tipo 12

Simulação com algoritmos genético Tipo 13

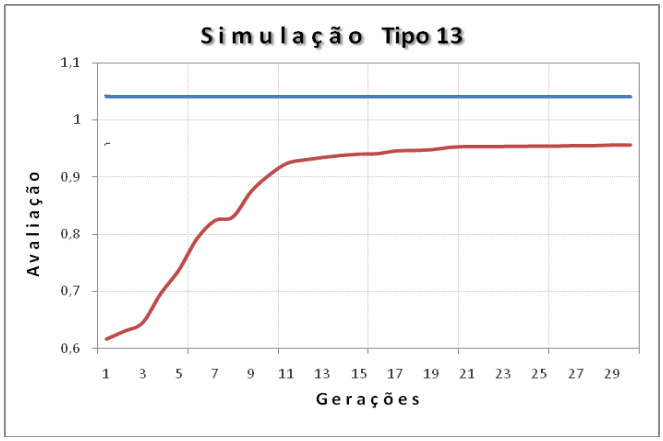

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,3**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 24 - Simulações com algoritmos genéticos tipo 13

Simulação com algoritmos genético Tipo 14

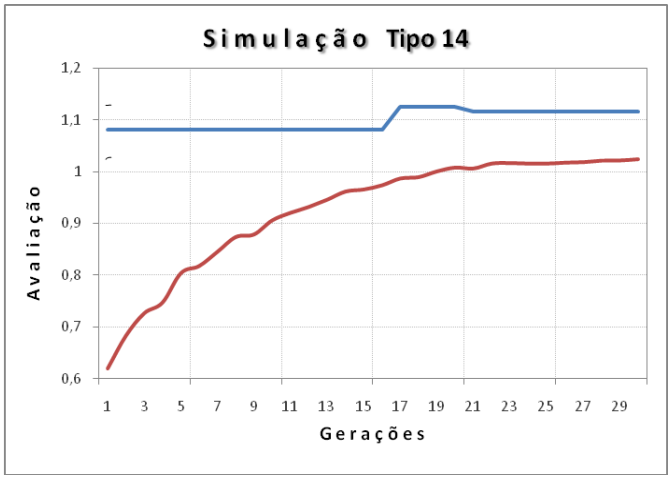

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,3**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 25 - Simulações com algoritmos genéticos tipo 14:

Simulação com algoritmos genético Tipo 15

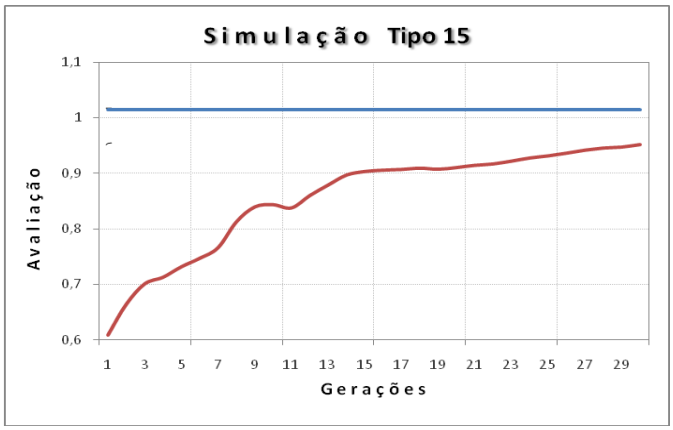

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,3**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 26 - Simulações com algoritmos genéticos tipo 15

Simulação com algoritmos genético Tipo 16

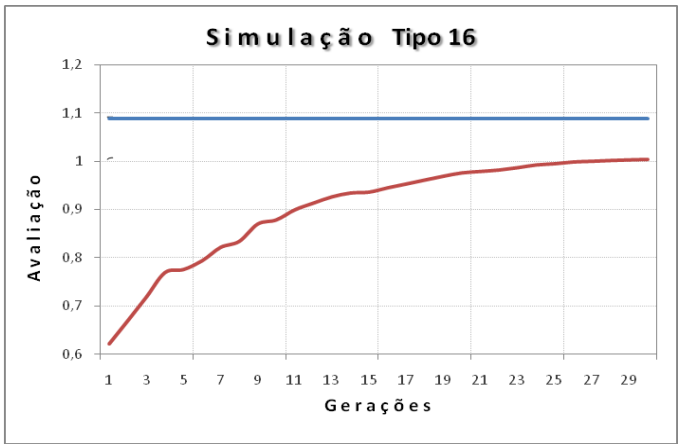

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,3**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 27 - Simulações com algoritmos genéticos tipo 16

Simulação com algoritmos genético Tipo 17

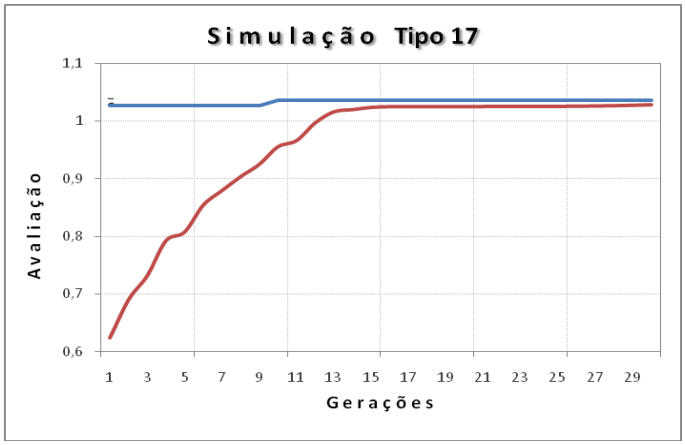

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,5**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 28 - Simulações com algoritmos genéticos tipo 17:

Simulação com algoritmos genético Tipo 18

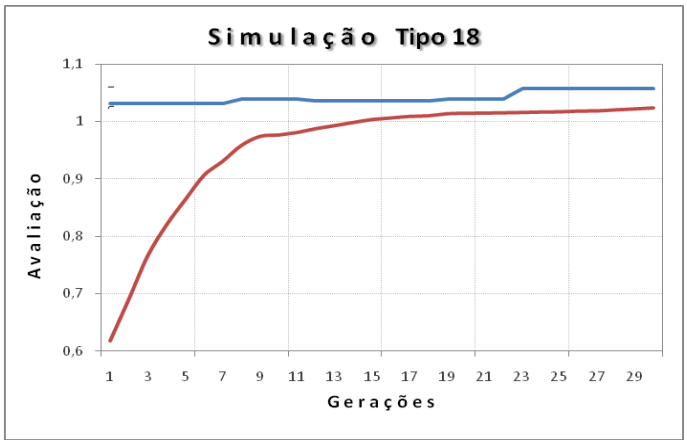

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,5**
Cruzamento	
(2 a 10 pontos)	**2**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 29 - Simulações com algoritmos genéticos tipo 18.

Simulação com algoritmos genético Tipo 19

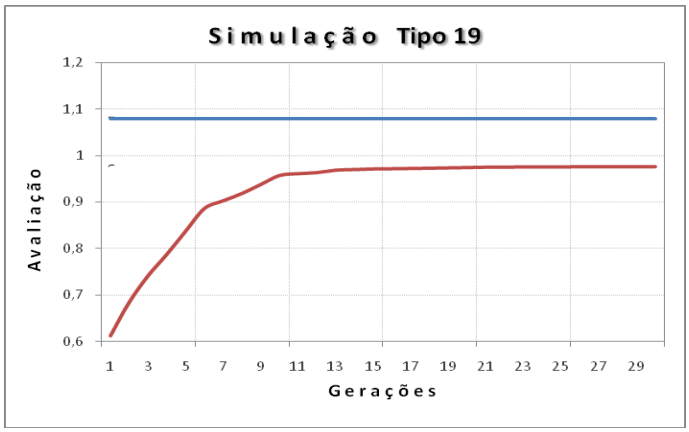

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,5**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**5%**

Gráfico 30 - Simulações com algoritmos genéticos tipo 19.

Simulação com algoritmos genético Tipo 20

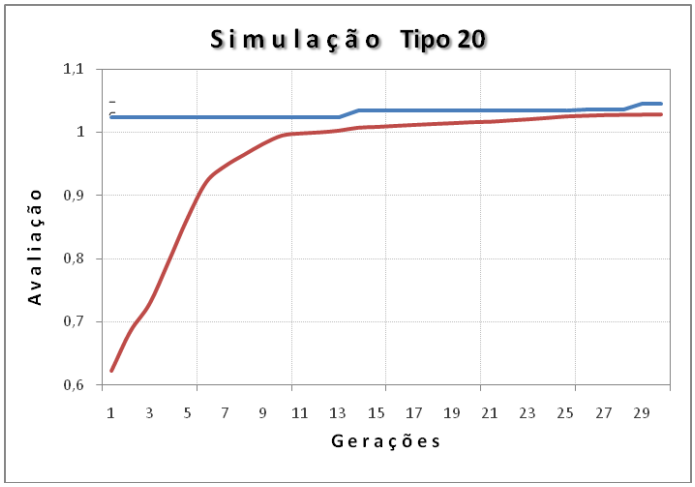

Parametros	Valores
Função Avaliação	
Fator K	**0,8**
Linear	**0,6**
Metodo de Seleção	Roleta
Elitismo	**3%**
Ranking	**1,5**
Cruzamento	
(2 a 10 pontos)	**10**
Intervalo de cruzamento	**85%**
Mutação	**10%**

Gráfico 31 - Simulações com algoritmos genéticos tipo 20:

:

Dados da Simulação com algoritmos genético Tipo 1

Tabela 17 – Simulação com algoritmos genético Tipo 1

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03
Média	0,61	0,69	0,71	0,73	0,74	0,79	0,81	0,81	0,85	0,87	0,88	0,88	0,89	0,89	0,90	0,90	0,91	0,91	0,92	0,93	0,93	0,93	0,93	0,93	0,93	0,93	0,93	0,92	0,92	0,93
Mínimo	0,26	0,46	0,48	0,56	0,56	0,64	0,66	0,66	0,72	0,72	0,72	0,80	0,80	0,80	0,85	0,85	0,85	0,85	0,85	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88	0,88
Desvio Padrão	0,20	0,14	0,12	0,12	0,11	0,10	0,09	0,08	0,07	0,06	0,06	0,05	0,05	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04

Dados da Simulação com algoritmos genético Tipo 2

Tabela 18 – Simulação com algoritmos genético Tipo 2

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,05	1,05	1,05
Média	0,63	0,69	0,70	0,77	0,81	0,84	0,87	0,88	0,89	0,90	0,90	0,91	0,91	0,91	0,92	0,92	0,91	0,92	0,91	0,91	0,92	0,92	0,92	0,92	0,92	0,92	0,92	0,93	0,93	0,93
Mínimo	0,26	0,42	0,49	0,55	0,58	0,62	0,68	0,81	0,81	0,81	0,81	0,81	0,81	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87	0,87
Desvio Padrão	0,23	0,17	0,17	0,15	0,13	0,10	0,07	0,06	0,06	0,05	0,05	0,05	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,03	0,04	0,03	0,03	0,03	0,03	0,03	0,02	0,02

Dados da Simulação com algoritmos genético Tipo 3

Tabela 19 – Simulação com algoritmos genético Tipo 3

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03
Média	0,62	0,69	0,72	0,75	0,79	0,82	0,84	0,85	0,86	0,87	0,88	0,88	0,89	0,90	0,90	0,90	0,90	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91	0,91
Mínimo	0,26	0,28	0,46	0,53	0,56	0,60	0,60	0,68	0,73	0,73	0,73	0,73	0,73	0,83	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89	0,89
Desvio Padrão	0,22	0,16	0,15	0,12	0,10	0,09	0,08	0,06	0,06	0,05	0,05	0,05	0,04	0,03	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02

Dados da Simulação com algoritmos genético Tipo 4

Tabela 20 – Simulação com algoritmos genético Tipo 4

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,05	1,06	1,06	1,06	1,06	1,06	1,06	1,06
Média	0,62	0,70	0,76	0,81	0,82	0,86	0,89	0,90	0,92	0,93	0,93	0,93	0,94	0,95	0,97	0,97	0,98	0,98	0,97	0,97	0,98	0,98	0,98	0,98	0,99	0,99	0,99	0,99	0,99	1,00
Mínimo	0,25	0,35	0,49	0,53	0,57	0,62	0,65	0,80	0,82	0,85	0,88	0,88	0,88	0,88	0,92	0,92	0,92	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,96
Desvio Padrão	0,22	0,17	0,16	0,14	0,12	0,10	0,07	0,06	0,05	0,04	0,04	0,05	0,04	0,04	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02

Dados da Simulação com algoritmos genético Tipo 5

Tabela 21 – Simulação com algoritmos genético Tipo 5

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03
Média	0,62	0,73	0,85	0,92	0,97	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Mínimo	0,26	0,41	0,58	0,65	0,90	0,96	0,97	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	0,98	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Desvio Padrão	0,22	0,17	0,14	0,09	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Dados da Simulação com algoritmos genético Tipo 6

Tabela 22 – Simulação com algoritmos genético Tipo 6

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06
Média	0,62	0,75	0,83	0,89	0,92	0,94	0,95	0,95	0,96	0,96	0,96	0,96	0,96	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,98	0,98	0,98	0,99	1,00	1,02	1,03	1,04	1,05
Mínimo	0,26	0,43	0,60	0,66	0,80	0,90	0,93	0,93	0,93	0,96	0,96	0,96	0,96	0,96	0,96	0,96	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,98	0,99	1,01	1,04
Desvio Padrão	0,22	0,15	0,12	0,07	0,04	0,02	0,02	0,02	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,02	0,02	0,02	0,02	0,03	0,02	0,02	0,01	0,00

Dados da Simulação com algoritmos genético Tipo 7

Tabela 23 – Simulação com algoritmos genético Tipo 7

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07
Média	0,63	0,75	0,83	0,93	0,98	1,00	1,02	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,05	1,05	1,05	1,06
Mínimo	0,26	0,45	0,53	0,71	0,81	0,94	0,98	1,01	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04
Desvio Padrão	0,23	0,18	0,15	0,09	0,05	0,03	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 8

Tabela 24 – Simulação com algoritmos genético Tipo 8

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,02	1,02	1,02	1,02	1,02	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04
Média	0,61	0,77	0,85	0,91	0,95	0,97	0,97	0,97	0,98	0,98	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,01	1,01	1,01	1,01	1,01
Mínimo	0,26	0,34	0,58	0,67	0,86	0,93	0,93	0,96	0,97	0,97	0,98	0,98	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	0,99	1,01
Desvio Padrão	0,21	0,16	0,11	0,08	0,03	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,01	0,00	0,01	0,00

Dados da Simulação com algoritmos genético Tipo 9

Tabela 25 – Simulação com algoritmos genético Tipo 9

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,05	1,05	1,05	1,05	1,05	1,05	1,05
Média	0,62	0,82	0,94	1,00	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,04	1,04
Mínimo	0,25	0,57	0,83	0,95	1,00	1,02	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04
Desvio Padrão	0,22	0,13	0,06	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Dados da Simulação com algoritmos genético Tipo 10

Tabela 26– Simulação com algoritmos genético Tipo 10

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09
Média	0,62	0,81	0,94	0,99	1,00	1,00	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,03
Mínimo	0,26	0,56	0,78	0,94	0,98	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,02	1,01	1,01	1,01	1,01	1,02	1,02	1,01	1,02	1,02	1,02	1,02
Desvio Padrão	0,22	0,13	0,06	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 11

Tabela 27 – Simulação com algoritmos genético Tipo 11

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,07	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08
Média	0,62	0,83	0,95	0,99	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02
Mínimo	0,26	0,59	0,81	0,93	1,00	1,00	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02
Desvio Padrão	0,21	0,13	0,05	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 12

Tabela 28 – Simulação com algoritmos genético Tipo 12

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,98	0,98	0,99	0,99	0,99	0,99	0,99	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04
Média	0,61	0,83	0,92	0,95	0,96	0,96	0,97	0,97	0,97	0,97	0,97	0,98	0,98	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Mínimo	0,26	0,59	0,81	0,92	0,95	0,96	0,96	0,96	0,97	0,97	0,97	0,97	0,98	0,98	0,98	0,99	0,99	0,99	0,99	0,99	0,99	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00	1,00
Desvio Padrão	0,21	0,11	0,03	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 13

Tabela 29 – Simulação com algoritmos genético Tipo 13

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04
Média	0,62	0,63	0,65	0,70	0,74	0,79	0,82	0,83	0,88	0,90	0,93	0,93	0,94	0,94	0,94	0,94	0,95	0,95	0,95	0,95	0,95	0,95	0,95	0,95	0,96	0,96	0,96	0,96	0,96	0,96
Mínimo	0,26	0,27	0,27	0,28	0,35	0,50	0,54	0,55	0,55	0,61	0,84	0,84	0,84	0,89	0,90	0,90	0,91	0,92	0,92	0,92	0,95	0,95	0,95	0,95	0,95	0,95	0,95	0,95	0,95	0,95
Desvio Padrão	0,22	0,22	0,21	0,19	0,17	0,15	0,15	0,14	0,11	0,07	0,03	0,03	0,03	0,03	0,02	0,02	0,02	0,02	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 14

Tabela 30 – Simulação com algoritmos genético Tipo 14

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,12	1,12	1,12	1,12	1,11	1,11	1,11	1,11	1,11	1,11	1,11	1,11	1,11	1,11
Média	0,62	0,68	0,73	0,75	0,80	0,82	0,85	0,87	0,88	0,91	0,92	0,93	0,95	0,96	0,97	0,97	0,99	0,99	1,00	1,01	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02
Mínimo	0,26	0,28	0,38	0,51	0,55	0,55	0,62	0,67	0,73	0,74	0,83	0,83	0,87	0,87	0,89	0,89	0,92	0,92	0,92	0,93	0,91	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,01
Desvio Padrão	0,22	0,19	0,14	0,14	0,13	0,13	0,12	0,10	0,09	0,08	0,06	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,04	0,03	0,03	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02

Dados da Simulação com algoritmos genético Tipo 15

Tabela 31 – Simulação com algoritmos genético Tipo 15

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02
Média	0,61	0,66	0,70	0,71	0,73	0,75	0,77	0,81	0,84	0,84	0,84	0,86	0,88	0,90	0,90	0,91	0,91	0,91	0,91	0,91	0,91	0,92	0,92	0,93	0,93	0,94	0,94	0,95	0,95	0,95
Mínimo	0,26	0,27	0,34	0,45	0,53	0,57	0,59	0,59	0,59	0,60	0,60	0,60	0,63	0,63	0,88	0,89	0,89	0,89	0,90	0,90	0,90	0,90	0,90	0,90	0,90	0,90	0,90	0,91	0,93	0,93
Desvio Padrão	0,21	0,19	0,18	0,16	0,15	0,14	0,14	0,13	0,11	0,10	0,10	0,09	0,07	0,05	0,02	0,02	0,02	0,03	0,02	0,02	0,03	0,03	0,03	0,03	0,02	0,02	0,02	0,02	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 16

Tabela 32 – Simulação com algoritmos genético Tipo 16

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09	1,09
Média	0,62	0,67	0,72	0,77	0,78	0,79	0,82	0,83	0,87	0,88	0,90	0,91	0,93	0,94	0,94	0,95	0,95	0,96	0,97	0,98	0,98	0,98	0,99	0,99	1,00	1,00	1,00	1,00	1,00	1,00
Mínimo	0,26	0,27	0,46	0,47	0,49	0,51	0,51	0,52	0,53	0,59	0,69	0,79	0,84	0,85	0,85	0,85	0,86	0,86	0,91	0,91	0,91	0,94	0,94	0,95	0,95	0,99	0,99	0,99	0,99	0,99
Desvio Padrão	0,22	0,20	0,16	0,16	0,15	0,14	0,13	0,13	0,10	0,10	0,07	0,06	0,05	0,04	0,04	0,04	0,04	0,04	0,03	0,03	0,03	0,03	0,02	0,02	0,02	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 17

Tabela 33 – Simulação com algoritmos genético Tipo 17

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04
Média	0,62	0,69	0,73	0,79	0,81	0,85	0,88	0,90	0,93	0,96	0,97	1,00	1,02	1,02	1,02	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03
Mínimo	0,26	0,28	0,46	0,54	0,54	0,54	0,57	0,69	0,69	0,69	0,83	0,88	0,94	0,94	0,97	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,03
Desvio Padrão	0,22	0,21	0,18	0,17	0,15	0,13	0,12	0,10	0,09	0,07	0,06	0,04	0,02	0,02	0,01	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00

Dados da Simulação com algoritmos genético Tipo 18

Tabela 34 – Simulação com algoritmos genético Tipo 18

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,03	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,06	1,06	1,06	1,06	1,06	1,06	1,06	1,06
Média	0,62	0,69	0,77	0,82	0,86	0,91	0,93	0,96	0,97	0,98	0,98	0,99	0,99	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,02
Mínimo	0,26	0,32	0,32	0,47	0,57	0,61	0,73	0,73	0,93	0,93	0,94	0,95	0,96	0,97	0,98	0,98	0,98	0,98	1,01	1,01	1,01	1,01	1,01	1,01	1,00	1,01	1,01	1,01	1,02	1,02
Desvio Padrão	0,22	0,21	0,19	0,17	0,14	0,12	0,09	0,05	0,03	0,02	0,02	0,02	0,02	0,02	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01

Dados da Simulação com algoritmos genético Tipo 19

Tabela 35 – Simulação com algoritmos genético Tipo 19

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08	1,08
Média	0,61	0,68	0,74	0,79	0,84	0,89	0,90	0,92	0,94	0,96	0,96	0,96	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,98	0,98	0,98	0,98	0,98	0,98	0,98	0,98
Mínimo	0,26	0,27	0,34	0,48	0,57	0,59	0,65	0,65	0,78	0,78	0,83	0,87	0,95	0,96	0,96	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97	0,97
Desvio Padrão	0,21	0,20	0,17	0,15	0,14	0,11	0,09	0,08	0,06	0,04	0,03	0,03	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02	0,02

Dados da Simulação com algoritmos genético Tipo 20

Tabela 36 – Simulação com algoritmos genético Tipo 20

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,02	1,02	1,02	1,02	1,02	1,02	1,02	1,03	1,03	1,03	1,03	1,03	1,03	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,04	1,05	1,05
Média	0,62	0,69	0,73	0,79	0,86	0,92	0,95	0,96	0,98	0,99	1,00	1,00	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,02	1,02	1,02	1,02	1,02	1,03	1,03	1,03	1,03	1,03	1,03
Mínimo	0,26	0,27	0,35	0,35	0,50	0,66	0,70	0,86	0,88	0,93	0,93	0,93	0,93	0,99	0,99	0,99	1,00	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,01	1,02	1,01	1,02
Desvio Padrão	0,23	0,22	0,20	0,18	0,14	0,09	0,07	0,04	0,03	0,02	0,02	0,02	0,02	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,01	0,00	0,00	0,00	0,00	0,00	0,00

ANEXO II

SIMULAÇÕES COM ALGORITMOS IMUNOLÓGICOS

Simulação com algoritmo de seleção clonal Tipo 1

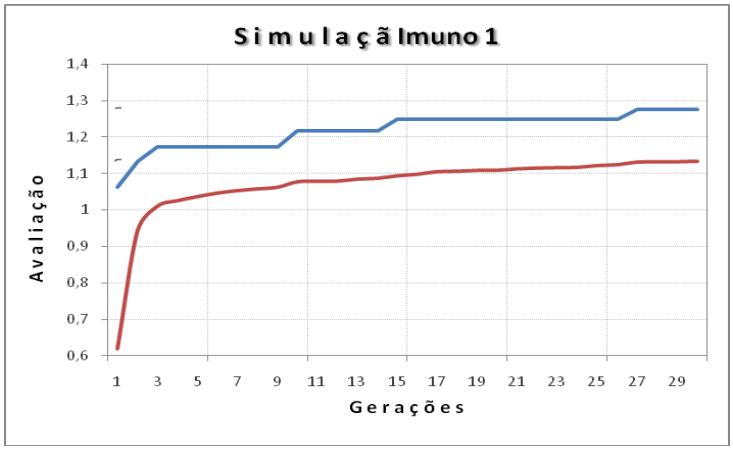

Parametros	Valores
Tamanho da População	50
Taxa de Mutação por indivíduor	20%
Número de Clones por indivíduo	10
Número de gerações	30

Gráfico 32 - Simulações com algoritmo de seleção clonal tipo 1

Simulação com algoritmo de seleção clonal Tipo 2

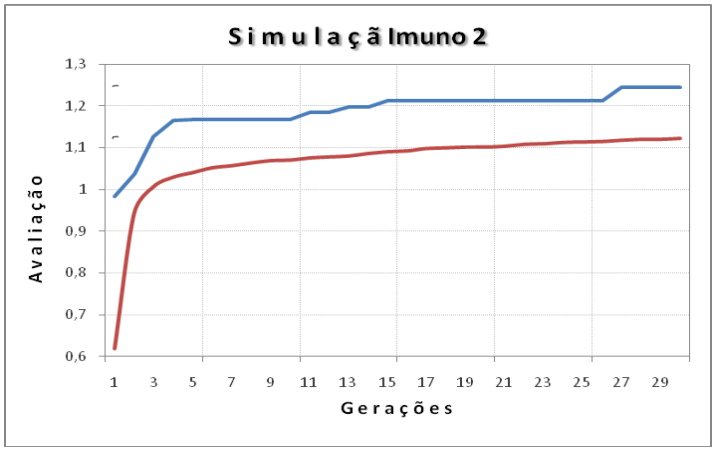

Parametros	Valores
Tamanho da População	50
Taxa de Mutação por indivíduor	50%
Número de Clones por indivíduo	10
Número de gerações	30

Gráfico 33 - Simulações com algoritmo de seleção clonal tipo 2

Dados da Simulação com de seleção clonal Tipo 1

Tabela 41 – Simulação com algoritmo de seleção clonal tipo 1

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	1,06	1,13	1,17	1,17	1,17	1,17	1,17	1,17	1,17	1,22	1,22	1,22	1,22	1,22	1,25	1,25	1,25	1,25	1,25	1,25	1,25	1,25	1,25	1,25	1,25	1,25	1,27	1,27	1,27	1,27
Média	0,62	0,94	1,01	1,03	1,04	1,05	1,05	1,06	1,06	1,08	1,08	1,08	1,08	1,09	1,09	1,10	1,11	1,11	1,11	1,11	1,11	1,12	1,12	1,12	1,12	1,12	1,13	1,13	1,13	1,13
Mínimo	0,26	0,89	0,96	0,98	0,99	1,00	1,01	1,02	1,02	1,03	1,04	1,04	1,05	1,05	1,05	1,06	1,06	1,06	1,07	1,07	1,07	1,08	1,08	1,08	1,08	1,08	1,09	1,09	1,09	1,09
Desvio Padrão	0,22	0,05	0,05	0,05	0,05	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04	0,04

Dados da Simulação com de seleção clonal Tipo 2

Tabela 42 – Simulação com algoritmo de seleção clonal tipo 2

Geração	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30
Máximo	0,98	1,04	1,13	1,17	1,17	1,17	1,17	1,17	1,17	1,17	1,18	1,18	1,20	1,20	1,21	1,21	1,21	1,21	1,21	1,21	1,21	1,21	1,21	1,21	1,21	1,21	1,24	1,24	1,24	1,24
Média	0,62	0,94	1,01	1,03	1,04	1,05	1,06	1,06	1,07	1,07	1,08	1,08	1,08	1,09	1,09	1,09	1,10	1,10	1,10	1,10	1,10	1,11	1,11	1,11	1,11	1,12	1,12	1,12	1,12	1,12
Mínimo	0,25	0,90	0,96	0,98	1,00	1,01	1,02	1,03	1,03	1,03	1,04	1,04	1,04	1,05	1,05	1,06	1,06	1,07	1,07	1,07	1,07	1,07	1,07	1,08	1,08	1,08	1,08	1,08	1,09	1,09
Desvio Padrão	0,22	0,04	0,04	0,04	0,04	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,04	0,04	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,03	0,04	0,04	0,04	0,04